

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

**FUKUNAGA-KOONTZ DÖNÜŞÜMÜ TABANLI
ALGORİTMALARIN GELİŞTİRİLMESİ VE HEDEF TESPİTİ-
SINIFLANDIRMA UYGULAMALARI**

HAMİDULLAH BİNOL

**DOKTORA TEZİ
ELEKTRONİK VE HABERLEŞME MÜHENDİSLİĞİ ANABİLİM DALI
HABERLEŞME PROGRAMI**

**DANIŞMAN
PROF. DR. HERMAN SEDEF**

İSTANBUL, 2016

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

FUKUNAGA-KOONTZ DÖNÜŞÜMÜ TABANLI
ALGORİTMALARIN GELİŞTİRİLMESİ VE HEDEF TESPİTİ-
SINIFLANDIRMA UYGULAMALARI

Hamidullah BİNOL tarafından hazırlanan tez çalışması 30.11.2016 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektronik ve Haberleşme Mühendisliği Anabilim Dalı'nda **DOKTORA TEZİ** olarak kabul edilmiştir.

Tez Danışmanı

Prof. Dr. Herman SEDEF
Yıldız Teknik Üniversitesi

Jüri Üyeleri

Prof. Dr. Herman SEDEF
Yıldız Teknik Üniversitesi

Prof. Dr. Sedef KENT PINAR
İstanbul Teknik Üniversitesi

Doç. Dr. Lütfiye DURAK ATA
İstanbul Teknik Üniversitesi

Yrd. Doç. Dr. Gökhan BİLGİN
Yıldız Teknik Üniversitesi

Yrd. Doç. Dr. Nihan KAHRAMAN
Yıldız Teknik Üniversitesi



Bu çalışma, Yıldız Teknik Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğü'nün 2015-04-03-DOP03 numaralı projesi ve TÜBİTAK 2211-C Yurt İçi Öncelikli Alanlar Doktora Burs Programı kapsamında desteklenmiştir.

ÖNSÖZ

Bu çalışma, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektronik ve Haberleşme Mühendisliği Anabilim Dalı Haberleşme Programı'nda "Fukunaga-Koontz Dönüşümü Tabanlı Algoritmaların Geliştirilmesi ve Hedef Tespiti-Sınıflandırma Uygulamaları" adlı doktora tezi olarak hazırlanmıştır.

Tez konunun belirlenmesi ve ilerlemesinde emeği geçen değerli hocalarıma, tez danışmanım Sayın Prof. Dr. Herman SEDEF'e ve tez izleme komitesi üyesi Sayın Yrd. Doç. Dr. Gökhan BİLGİN'e değerli katkılarından ve desteklerinden dolayı şükranlarımı sunuyorum.

Aralarına katıldığım andan itibaren gösterdikleri sıcak ilgi ve sağladıkları uygun çalışma ortamı nedeniyle Yıldız Teknik Üniversitesi ve özellikle Elektronik ve Haberleşme Mühendisliği Bölümü ailesine ve bilgi, tecrübe ve arkadaşlıklarıyla yanımda olan başta Arş. Gör. Hüseyin ÇUKUR olmak üzere çalışma arkadaşlarıma da teşekkürü bir borç bilirim.

Son ama bir o kadar da önemli olarak, üzerimdeki emeklerini hayatımın her anında hissettiğim değerli aileme ve hayat arkadaşım sevgili eşime sevgilerimi sunarım. Onların ilgi ve destekleri olmasaydı, bu uzun yol şüphesiz daha zor ve meşakkatli geçecekti.

Ekim, 2016

Hamidullah BİNOL

İÇİNDEKİLER

	Sayfa
SİMGE LİSTESİ.....	vii
KISALTMA LİSTESİ	viii
ŞEKİL LİSTESİ.....	x
ÇİZELGE LİSTESİ	xi
ÖZET.....	xiii
ABSTRACT.....	xv
BÖLÜM 1	
GİRİŞ.....	1
1.1 Literatür Özeti.....	1
1.2 Tezin Amacı.....	5
1.3 Hipotez.....	6
BÖLÜM 2	
HEDEF TESPİTİ VE SINIFLANDIRMA PROBLEMİNE GENEL BAKIŞ.....	7
2.1 Hiperspektral Görüntüleme.....	7
2.2 Hedef Tespiti ve Sınıflandırma Problemi	9
BÖLÜM 3	
DOĞRUSAL VE DOĞRUSAL OLMAYAN FUKUNAGA-KOONTZ DÖNÜŞÜMÜ.....	14
3.1 Fukunaga-Koontz Dönüşümü	14
3.2 Çekirdek Fukunaga-Koontz Dönüşümü	17
3.2.1 Kompozisyonel Çekirdek Birleşimi.....	19
3.2.2 Bileşik Çekirdekler	20
3.2.2.1 Çekirdeklerin Doğrudan Toplamı	21
3.2.2.2 Çekirdeklerin Ağırlıklı Toplamı	21
3.2.2.3 Çapraz-bilgi Taşıyan Çekirdek	22
3.2.3 Çoklu-çekirdek Öğrenmesi	22
3.2.3.1 Çoklu-çekirdek Öğrenmesi ve Topluluk Öğrenme İlişkisi.....	23
3.3 ÇFKD için Çekirdek Parametresi Seçimi	27

3.4	Deneysel Sonular	30
BÖLÜM 4		
YÜKSEK BOYUTLU VERİLERDE BOYUT AZALTMA.....		53
4.1	Temel Bileşen Analizi (TBA) ile Boyut Azaltma	53
4.2	FKD ile Boyut Azaltma	55
4.3	ÇFKD ile Boyut Azaltma	56
4.4	Deneysel Sonular	57
BÖLÜM 5		
TEK-SINIFLI FKD ALGORİTMALARI		64
5.1	Tek-sınıflı FKD.....	64
5.2	Tek-sınıflı ÇFKD.....	66
5.3	Topluluk Öğrenme Yaklaşımı ile Tek-sınıflı ÇÇFKD	67
5.4	Tek-sınıflı Seçici ÇÇFKD	69
5.5	Deneysel Sonular	69
BÖLÜM 6		
SONUÇ VE ÖNERİLER.....		78
KAYNAKLAR		87
ÖZGEÇMİŞ		93

SİMGE LİSTESİ

I	Birim matris
$(.)_{\perp}$	Dikgen tamamlayıcı
P	Dönüşüm operatörü
ϕ	Eşleme kuralı
κ	Kappa katsayısı
Σ	Kovaryans matrisi
$(.)^{\top}$	Matris devriği
$\mathcal{L}(\cdot)$	Olabilirlik oranı
μ	Ortalama
x	Öznelik vektörü

KISALTMA LİSTESİ

AAA	Ayrırma Alt uzay Analizi
AÇK	Alıcı Çalışma Karakteristiği
AVIRIS	Airborne Visible InfraRed Imaging Spectrometer
AWGN	Additive White Gaussian Noise
BÇ	Bileşik Çekirdekler
ÇÇÖ	Çoklu-çekirdek Öğrenmesi
ÇÇHU	Çoğaltma Çekirdek Hilbert Uzayı
ÇFKD	Çekirdek Fukunaga-Koontz Dönüşümü
ÇTBA	Çekirdek Temel Bileşen Analizi
DAA	Doğrusal Ayrırma Analizi
DGA	Diferansiyel Gelişim Algoritması
DVM	Destek Vektör Makinaları
EAA	Eğri Altında kalan Alan
FKD	Fukunaga-Koontz Dönüşümü
GGO	Geri Getirme Oranı
HGS	Hiperspektral Görüntüleme Sistemleri
HYDICE	Hyperspectral Digital Imagery Collection Experiment
İİS	İkinci-dereceden İlinti Süzgeçleri
KÇB	Kompozisyonel Çekirdek Birleşimi
OO	Olabilirlik Oranı
QCF	Quadratic Correlation Filter
RGB	Red Green Blue
RTF	Radyal Tabanlı Fonksiyon
SAH	Spektral Açık Haritalayıcısı
SNR	Signal to Noise Ratio
SPECIM	SPECTral IMaging
SWIR	Short-Wave Infrared
TBA	Temel Bileşen Analizi
TÖ	Topluluk Öğrenme
TS-FKD	Tek-sınıflı Fukunaga-Koontz Dönüşümü
TS-ÇFKD	Tek-sınıflı Çekirdek Fukunaga-Koontz Dönüşümü
TS-ÇÇFKD	Tek-sınıflı Çoklu-çekirdek Fukunaga-Koontz Dönüşümü

TS-SÇFKD	Tek-sınıflı Seçici Çoklu-çekirdek Fukunaga-Koontz Dönüşümü
UA	Uzaktan Algılama
VNIR	Visible and Near-Infrared
YAO	Yanlış Alarm Oranı



ŞEKİL LİSTESİ

	Sayfa
Şekil 2.1	Hiperspektral küp verisi ve spektral imza 8
Şekil 2.2	Hedef tespiti ve sınıflandırmanın teorisi ve pratik durum 12
Şekil 3.1	Tüm veri uzayının FKD ile dört alt uzaya bölünmesi 15
Şekil 3.2	Farklı σ değerleri ile geri getirme oranının değişimi (üst) <i>Corn-no till</i> (alt) <i>Grass / pasture</i> 27
Şekil 3.3	<i>Corn-no till</i> (sol) ve <i>Grass / pasture</i> (sağ) için σ değerlerine karşılık $J(\sigma)$ değişimi 29
Şekil 3.4	<i>Indian Pine</i> hiperspektral verisinin bir kısmı 31
Şekil 3.5	<i>DC Mall</i> hiperspektral verisinin bir kısmı 31
Şekil 3.6	Hiperspektral görüntüleme sisteminin şematik diyagramı 37
Şekil 3.7	Kıyma eti görüntüleri 37
Şekil 3.8	Kıyma etine ait örnek spektral imzalar 38
Şekil 3.9	AVIRIS algılayıcıları ile alınmış kuzeybatı Tippecanoe, Indiana test alanı (üst) Seçilmiş üç sınıf için rasgele toplanan 50 örnek ortalaması ile elde edilmiş spektral vektörler (alt) 39
Şekil 3.10	HyMap hiperspektral verisinin bir kısmı ve V_1 , V_2 , and V_3 hedeflerine ait referans ilgi alanları ile doğrulama fotoğrafları 40
Şekil 3.11	<i>Indian Pine</i> veri kümesi <i>soybean-no till</i> (sol), <i>soybean-min till</i> (orta) ve <i>soybean-clean till</i> (sağ) sınıfları için üretilmiş GGO-YAO eğrileri 41
Şekil 3.12	<i>Indian Pine</i> veri kümesi <i>soybean-no till</i> (üst), <i>soybean-min till</i> (orta) ve <i>soybean-clean till</i> (alt) sınıfları için YAO (10 deney ortalaması) değerlerinin eğitim örnekleri sayısı ile değişimi 42
Şekil 3.13	HyMap verisi hedef tespiti senaryosu 43
Şekil 3.14	V_1 hedefi için KB-ÇFKD algoritması tespit sonuçlarının gösterimi 44
Şekil 4.1	Temel bileşen analizinin geometrik yorumu 54
Şekil 4.2	Çatalca verisinin alt sahneleri 57
Şekil 4.3	Pavia Üniversite verisinin alt sahneleri 58
Şekil 4.4	V_2 (üstte), asfalt (ortada), ve tuğla (altta) için sigma değerlerine karşılık üretilen Kappa katsayıları 59
Şekil 4.5	Farklı yöntemlerle üretilen baskın bileşenler 60
Şekil 4.6	Farklı boyutlara karşı üretilen Kappa katsayıları 61
Şekil 5.1	FKD ve üç farklı katsayı için TS-FKD'nin ayırt edici alt uzayları 66
Şekil 5.2	TS-FKD ve TS-ÇFKD sınıflandırma doğruluğunun seçilmiş sınıflar üzerinde parametre değerine göre değişimi 70
Şekil 5.3	Sınıflandırma doğruluğunun eğitim kümesi oranına göre değişimi 71

ÇİZELGE LİSTESİ

	Sayfa
Çizelge 3.1 <i>Indian Pine</i> ve <i>DC Mall</i> verilerine ait sınıf bilgisi	32
Çizelge 3.2 Kullanılan çekirdekler	33
Çizelge 3.3 Orijinal, TBA ve ÇTBA öznitelikleri kullanılarak farklı sayıda eğitim örnekleri ile üretilen DVM genel sınıflandırma doğruluğu	34
Çizelge 3.4 Farklı eğitim örnekleri ile 9 sınıflı <i>Indian Pine</i> verisinde elde edilen genel sınıflandırma doğrulukları	34
Çizelge 3.5 Farklı eğitim örnekleri ile 16 sınıflı <i>Indian Pine</i> verisinde elde edilen genel sınıflandırma doğrulukları	35
Çizelge 3.6 Farklı eğitim örnekleri ile <i>DC Mall</i> verisinde elde edilen genel sınıflandırma doğrulukları	35
Çizelge 3.7 Yağ içeriğinin gerçek ve tahmin edilen yüzdeleri	38
Çizelge 3.8 DGA ile elde edilen RTF parametreleri ve ÇFKD ile KB-ÇFKD yöntemlerinin karşılaştırması.....	41
Çizelge 3.9 Algoritmaların GGO ve YAO değerleri	45
Çizelge 3.10 Tek ve bileşik çekirdekler için GGO-YAO eğrisi altında kalan alanlar..	46
Çizelge 3.11 Kullanılan veriler hakkında özet bilgi	48
Çizelge 3.12 Kullanılan çekirdekler	49
Çizelge 3.13 RTF çekirdek için 10 bağımsız koşturmaya ait sınıflandırma doğruluğu ve Kappa katsayısı değerleri	49
Çizelge 3.14 Küresel çekirdek için 10 bağımsız koşturmaya ait sınıflandırma doğruluğu ve Kappa katsayısı değerleri.....	50
Çizelge 3.15 Parametre seçimi için test sınıfları.....	51
Çizelge 3.16 <i>Indian Pine</i> verisi seçilmiş sınıflar için parametre seçme sonuçları	51
Çizelge 3.17 Yöntemlerin ortalama hesaplama süreleri	52
Çizelge 4.1 Boyut azaltma için kullanılan hedef sınıf eğitim ve test örnekleri sayısı ..	58
Çizelge 4.2 Farklı yöntemlerle üretilen Doğruluk, Geri getirme ve Kappa değerleri ..	62
Çizelge 5.1 Kullanılan veri kümeleri	69
Çizelge 5.2 Farklı doğrusal tek-sınıflı sınıflandırma yöntemlerinin sınıflandırma doğrulukları.....	72
Çizelge 5.3 Farklı doğrusal olmayan tek-sınıflı sınıflandırma yöntemlerinin sınıflandırma doğrulukları	73
Çizelge 5.4 Tekli ve çoklu çekirdek yöntemlerinin sınıflandırma doğrulukları.....	74
Çizelge 5.5 <i>DC Mall</i> verisi sınıfları hakkında bilgi.....	75
Çizelge 5.6 Hedeflerin doğrusal yöntemlerle EAA değerlerinin 10 bağımsız koşturma ortalaması ($a = 2$)	75
Çizelge 5.7 Hedeflerin doğrusal yöntemlerle EAA değerlerinin 10 bağımsız koşturma	

	ortalaması ($a = 10$).....	76
Çizelge 5.8	Hedeflerin doğrusal olmayan yöntemlerle EAA değerlerinin 10 bağımsız koşurma ortalaması ($a = 2$).....	76
Çizelge 5.9	Hedeflerin doğrusal olmayan yöntemlerle EAA değerlerinin 10 bağımsız koşurma ortalaması ($a = 10$).....	77



FUKUNAGA-KOONTZ DÖNÜŞÜMÜ TABANLI ALGORİTMALARIN GELİŞTİRİLMESİ VE HEDEF TESPİTİ- SINIFLANDIRMA UYGULAMALARI

Hamidullah BİNOL

Elektronik ve Haberleşme Mühendisliği Anabilim Dalı

Doktora Tezi

Tez Danışmanı: Prof. Dr. Herman SEDEF

Teknolojinin gelişmesiyle, sayısal görüntüleme sistemleri günümüzde birçok alanda uygulanmasının yanında, bir ihtiyaç haline gelmiştir. Hedef tespiti ve sınıflandırma problemleri, başta askeri alanlar olmak üzere sağıktan uzay araştırmalarına kadar birçok sektörün ilgisini çekmektedir.

Farklı tür görüntülerde hedef tespiti ve sınıflandırma yapılabilmekle birlikte, sağladığı materyale özgü yüksek spektral bilgi nedeniyle hiperspektral görüntüleme sistemleri, askeri ve sivil uygulamalarda artan bir eğilimle kullanılmaktadır.

Bu tezde, hiperspektral görüntüler üzerinde hedef tespiti ve sınıflandırma görevlerinin etkin bir şekilde başarımı için Fukunaga-Koontz Dönüşümü (FKD) ve çekirdek FKD (ÇFKD) tabanlı algoritmaların geliştirilmesi üzerinde durulmuştur. Geliştirilen algoritmalar ayrıca literatürde sıkça kullanılan makine öğrenmesi karşılaştırma verileri üzerinde de test edilmiştir.

Çekirdek-tabanlı yöntemlerin avantajları kullanılarak, literatürde mevcut olan sabit çekirdekli ÇFKD yaklaşımının kompozisyonel çekirdek birleşimi, bileşik çekirdekler ve çoklu-çekirdek öğrenmesi stratejileri ile genişletilmesi çalışmaları gerçekleştirilmiştir. Bunun yanında, yine literatürde ÇFKD için çalışılmamış olan, çekirdek parametresi seçimi problemi için bir yöntem önerilmiştir. Yapılan deneyler, bileşik çekirdekler hariç diğer yaklaşımların, klasik ÇFKD performansını geliştirdiğini göstermiştir. Bileşik

çekirdekler yaklaşımı ile istenen başarının sağlanamamasında, kullanılan veri ve çekirdek yapılarının etkisinin olduğu düşünülmektedir. Tez kapsamında geliştirilen ÇFKD için çekirdek parametresi seçimi yönteminin de, araştırmacıların sıklıkla tercih ettiği çapraz-doğrulama tabanlı yöntemlere göre özellikle işlem hızı açısından üstün olduğu görülmüştür.

Hiperspektral görüntülerin sağladığı yüksek çözünürlükte spektral bilginin, verinin saklanması, işlenmesi ve iletilmesi aşamalarında ortaya çıkardığı bazı dezavantajlar da bulunmaktadır. Yüksek boyutluluk kaynaklı bu dezavantajların giderilmesi için boyut azaltma başlığı altında çalışmalar yapılmaktadır. Eğitici ve eğitici olarak kategorilendirilebilecek bu çalışmalar ile yüksek boyutlu veri, bilgi içeriğinin olabildiğince korunduğu bir formda temsil edilir. Literatürde eğitici yapıda işleyen yöntemlerin, veride mevcut sınıf ve/veya hedef bilgisinin korunmasında yetersiz kalabildiği bilinmektedir. FKD-tabanlı ayırma yönteminin hedef sınıf odaklı olması ve öznelik çıkarmadaki başarısı, hedef yönelimli bir boyut azaltma tekniğinin geliştirilmesi için itici güç olmuştur. FKD-tabanlı boyut azaltma yönteminin temel bileşen analizi (TBA) ile karşılaştırılmasında, istenen sınıflandırma performansı artışının alınamadığı anlaşılmıştır. Buradan hareketle, çekirdek-tabanlı öğrenmenin de avantajını kullanmak amacıyla, bir ÇFKD-tabanlı hedef yönelimli boyut azaltma algoritması tez kapsamında geliştirilmiştir. Gerçek hiperspektral sahnelerde hedef-arka plan ayrımı amacıyla yürütülen deneyler, önerilen algoritmanın FKD ve TBA özneliklerine göre daha gürbüz öznelikler çıkardığını göstermiştir.

FKD algoritmasının temelde iki-sınıflı işleme, yalnız hedef sınıf eğitim örneklerinin toplanabildiği uygulamalarda kullanılamamasına neden olmaktadır. Bu dezavantajı ortadan kaldırmak ve eğitici hedef tespiti problemlerinde kullanılabilecek bir tek-sınıflı yöntem elde etmek için, tezin son aşamasında FKD-tabanlı tek-sınıflı sınıflandırma algoritmaları önerilmiştir. Yöntemin ana fikri, mevcut belirli bir hedef veya sınıfa ait öznelikleri kullanarak, bu özneliklerin oluşturduğu vektör zarfının dışında yapay örnekler oluşturmaya dayanmaktadır. Bu yöntemin, veri-içinden daha çok bilgi toplayan klasik FKD yaklaşımına göre uygun koşullar altında daha yüksek ve kararlı performans gösterebileceği yapılan deneylerle doğrulanmıştır. Tek-sınıflı FKD (TS-FKD) olarak adlandırılan bu yöntemin, çekirdek (TS-ÇFKD), çoklu-çekirdek (TS-ÇÇFKD) ve seçici çoklu-çekirdek (TS-SÇÇFKD) versiyonları da geliştirilmiş ve literatürdeki bilinen tek-sınıflı sınıflandırma yöntemleri ile karşılaştırılmıştır. Karşılaştırmalı testler, önerilen algoritmaların, popüler tek-sınıflı yöntemlere güçlü birer alternatif olabilecekleri sonucunu üretmiştir.

Anahtar Kelimeler: Boyut Azaltma, Çekirdek-tabanlı Öğrenme, Fukunaga-Koontz Dönüşümü, Hedef Tespiti ve Sınıflandırma, Tek-sınıflı Sınıflandırma

**DEVELOPMENT OF FUKUNAGA-KOONTZ TRANSFORM
BASED ALGORITHMS AND TARGET DETECTION-
CLASSIFICATION APPLICATIONS**

Hamidullah BINOL

Department of Electronics and Communications Engineering

Ph.D. Thesis

Adviser: Prof. Dr. Herman SEDEF

With advances in technology, digital imaging systems have become a necessity and are being used in varied areas of daily life. Target detection and classification problems have especially been in the forefront as they are used in fields as diverse as medicine and space research and hold special importance for military systems.

Although target detection and classification can be carried out on different types of images, due to the material-specific high spectral information provided by them, hyperspectral imaging systems are being used increasingly in military and civilian applications.

In this thesis, in order to effectively implement target detection and classification tasks on hyperspectral images, the focus is on the development of Fukunaga-Koontz Transform (FKT) and kernel FKT (KFKT) based algorithms. The developed algorithms have also been tested on low-dimensional benchmark data sets which are commonly used in literature in this discipline.

Using the advantages of kernel-based learning methods, KFKT with a single kernel (studies on which are available in the literature) has been expanded employing compositional kernel combination, composite kernels, and multiple-kernel learning strategies. Besides these strategies, a new technique for the selection of a kernel parameter is also proposed; this method has not been discussed in existing literature on KFKT. The experiments demonstrate that all the techniques except composite kernels improve the performance of classical KFKT. It is thought to be the effect of utilized data and kernel

structures that collectively fail to provide the desired outcomes via composite kernels. Experiments also indicate that the suggested kernel parameter selection method is superior to well-known cross-validation based techniques, particularly in terms of processing speed.

High-resolution spectral information of hyperspectral images, however, has some disadvantages that can occur in the storage, processing, and transmission of data. Dimensionality reduction (DR) techniques are performed to eliminate these drawbacks caused by their high dimensionality. The high-dimensional data is represented by supervised or unsupervised DR methods in a more condensed form, while preserving the information content in the data as much as possible. Unsupervised methods are known to be inadequate in protecting the information of the target and/or class inherent in the data. Feature extraction capability and class-focused characteristic of the FKD-based discrimination method have been important driving forces for the development of a target-oriented DR technique. When compared with PCA, it is found that the classification performance for FKT features is lower than that of PCA. Therefore, taking advantage of kernel-based learners, a KFKT-based target-oriented DR algorithm has been developed in this thesis. Target-background separation experiments conducted on real hyperspectral images have shown that the proposed algorithm can extract more robust features than FKT and PCA can.

An important disadvantage of the two-class characteristic of classical FKT algorithm is that it is unusable in applications where only the training samples of target class are used. To eliminate this disadvantage and obtain a one-class classification technique which can be employed in supervised target detection problems, FKT-based one-class classification algorithms have been suggested in the final stage of the thesis. The main idea behind this technique is based on construction of synthetic samples that are out of the positive class (target class) with their boundaries delineated by using features that belong to the existing target or class. It has been confirmed by experiments that this method, under appropriate conditions, can show a better and more stable performance than classical FKT. Kernel OC-FKT (OC-KFKT), multiple-kernel OC-FKT (OC-MKFKT), and selective multiple-kernel OC-FKT (OC-SMKFKT) versions of this method, called one-class FKT (OC-FKT), have also been developed and compared with a few one-class classification methods known in the literature in this field. Results of comparative experiments show that the proposed algorithms are apt alternatives to commonly used one-class methods.

Keywords: Dimensionality Reduction, Fukunaga-Koontz Transform, Kernel-based Learning, One-class Classification, Target Detection and Classification

1.1 Literatür Özeti

Hedef tespiti ve sınıflandırma birçok askeri ve güvenlik uygulamasının önemli bir görevidir. Bu alandaki akademik çalışmalar, literatürde bilgisayarla görme (*computer vision*) üst başlığı altında yer almaktadır. Sahadan elde edilen pekçok veri türü yardımıyla bu görevler yapılabilmekte ise de, bilgisayar ve elektronik teknolojisinin de gelişmesiyle, optik uzaktan algılama verileri (doğal renkli görüntüler, termal görüntüler, hiperspektral görüntüler vs.) üzerinde gerçekleştirilen uygulamalar gün geçtikçe popülaritesini artırmaktadır.

Uzaktan algılamada, gözetimli hedef tespiti bir iki-sınıflı (ki bu sınıflar hedef ve arka plan karışıklığı olarak adlandırılır) ayırma/sınıflandırma problemi olarak düşünülebilir [1]. Elbette bu kabul, hedef tespiti probleminin doğasını tümüyle yansıtmamaktadır. Bu problemin daha kapsamlı çözüm yollarından ilerleyen bölümlerde bahsedilecektir. Hedef tespitinin bir sınıflandırma problemi olarak ele alınmasına geri dönersek, literatürde önerilmiş pekçok teknikle karşılaşmak mümkündür. Bu teknikler arasında, sınıflar arası uzaklığı artırmaya çalışan ikinci-dereceden ilinti süzgeçleri (İİS) en popüler olanlardan biridir [2], [3]. Fukunaga-Koontz Dönüşümü (FKD) [4], İİS tasarımında bir uygun katsayı matrisinin elde edilmesi için kullanılmıştır [5]. FKD, 1970 yılında bir öznitelik seçme ve sıralama yaklaşımı olarak önerildikten sonra hedef tanıma [6] ve yüz tespiti [7] gibi görüntü tanıma uygulamalarında kullanılmıştır. Yöntemin temeli tıpkı temel bileşen analizinde (TBA) olduğu gibi Karhunen-Loève dönüşümüne dayanmaktadır. FKD, normal (Gaussian) dağılımlı verilerde kullanılmaya elverişli ve ikinci-dereceden istatistiksel özellikleri çıkarmaya uygundur [8]. Bu durum, karmaşık yapıdaki gerçek

verilerde (örn. hiperspektral veriler) sözü edilen tekniğin tatmin edici performans gösterememesinin en önemli nedenidir. Bu kısıtın giderilmesi, bu tez çalışmasının motivasyonunun önemli bir parçasıdır.

Özellikle son yirmi yılda, çekirdek-tabanlı öğrenme yöntemleri, verideki doğrusal olmayan ilişkilerin keşfedilmesindeki yeteneğiyle araştırmacıların büyük ilgisini çekmektedir. Liu vd. [5] çekirdek yöntemlerden yararlanarak FKD'yi doğrusal olmayan versiyonuna genelleştirmişler ve kızılötesi görüntülerde küçük hedeflerin tespiti amacıyla kullanmışlardır. Çekirdek FKD (ÇFKD) olarak adlandırılan bu yöntem, yüz tanıma [9] ve hiperspektral görüntülerde hedef tanıma [10] uygulamalarında tatmin edici performans göstermiştir. Bu uygulamalarda, ÇFKD geliştirme aşamasında önceden belirlenmiş tek bir çekirdek kullanılmış ve (varsa) çekirdek parametresi seçimi için bir öneri getirilmemiştir. Bununla birlikte, uygun çekirdek ve parametrelerinin seçimi üzerine yapılan çalışmalar göstermiştir ki, her senaryo ve veri için geçerli bir en iyi çekirdek yoktur ve çekirdek parametresinin doğru belirlenmesi sistem performansına pozitif etki etmektedir [11]. Binol vd. [12] tarafından bu tez kapsamında gerçekleştirilen çalışmada da, farklı çekirdek fonksiyonlarının hiperspektral görüntülerde sınıflandırma performansına etkisi ortaya koyulmuştur. Bunun yanında, çekirdek parametresi seçimi için FKD'nin ayırma yeteneğinin artırılmasını göz önünde bulunduran bir optimizasyon problemi [13] geliştirilmiş ve diferansiyel gelişim algoritması (DGA) [14] ile çözülmüştür.

Pratikte, her veri ve uygulama için geçerli “en iyi çekirdek” olarak nitelendirilebilecek bir formülizasyon bulunmadığından, tek bir çekirdek yerine farklı çekirdeklerin veri üzerindeki farklı karakteristikleri aynı anda çıkarmalarını sağlamak için, araştırmacılar çekirdek birleşimi yöntemlerine yönelmiştir. Bunlardan en klasik ve ilkel olanı çekirdek çıktılarının ortalamasını almaktır. Bu durum aynı zamanda, ağırlıksız bir doğrusal birleşim olarak da ifade edilebilir. Ayrıca, çeşitli optimizasyon yöntemleri ve sezgisel yaklaşımlar da çekirdek ağırlıklarını belirlemek için kullanılmıştır [15]-[19]. Buraya kadar bahsedilen kavramlar çoklu-çekirdek öğrenmesi (ÇÇÖ) çerçevesinde literatürde kendisine genişçe yer bulmuştur. Bu tez kapsamında da, ÇÇÖ üzerinde durulmuş ve FKD yönteminin gelişmiş bir uygulaması için işleme sokulmuştur. ÇÇÖ yönteminden ve bu uygulamanın teorik altyapısından ileride bahsedilecektir.

Yukarıda bahsedilen ağırlıkları belirleme tabanlı bu yöntemlerde, orijinal çekirdek etkisinin kaybolma riski vardır. Lee vd. [20] bu dezavantajı gidermeye yönelik, orijinal dönüşüm matrislerinin değiştirilmeden kullanıldığı kompozisyonel çekirdek birleşimi (KÇB) adını verdikleri bir yöntem geliştirmişlerdir. Bu tez kapsamında, KÇB yaklaşımının hiperspektral görüntülerde hedef tespiti amaçlı FKD yöntemine uygulanması üzerinde de durulmuştur.

Hiperspektral görüntülerin işlenmesi ile ilgili yaygın kullanım biçimi, içerdiği zengin spektral bilgiden yararlanma üzerinedir [21]. Bu durum, sınıflandırma ve çekirdek yöntemlerin dâhil edildiği uygulamalar için de geçerlidir. Esasında, bu haliyle dahi birçok problem için tatmin edici sonuçlar üretilebilmektedir. Bununla birlikte, hiperspektral algılayıcı teknolojisindeki gelişmelere paralel olarak yer çözünürlüğündeki iyileşmeler, yalnız uzamsal özniteliklerin de anlamlı sonuçlar üretmesine imkân vermiştir. Literatürde spektral bilginin uzamsal çeşitliliğini dikkate alan çekirdek yöntemler yalnız spektral boyutun kullanıldığı çalışmalara göre oldukça azdır. Camps-Valls vd. [22] yaptıkları çalışmada çekirdek ailesinin özelliklerini kullanarak spektral, uzamsal ve bu ikisinin çapraz bilgisinin kullanıldığı bir çekirdek ailesi oluşturmuşlardır. Oluşturulan bileşik çekirdekler, destek vektör makineleri (DVM) ile hiperspektral görüntülerde sınıflandırma amacıyla kullanılmış ve yalnız spektral bilginin kullanıldığı duruma göre başarılı sonuçlar alınmıştır. Bu tez kapsamında da, hiperspektral görüntülerde spektral özniteliklerden ve uzamsal komşuluk ilişkisinden bir arada faydalanmak amacıyla seçilen bir bileşik çekirdek ailesi ÇFKD algoritmasının oluşturulmasında kullanılmış ve karşılaştırmalı testler gerçekleştirilmiştir.

Farklı çekirdek dönüşümlerinin arasından belirli bir problem için en iyisinin araştırılması problemine farklı yollarla çözümler aransa da, ÇÇÖ yaklaşımı literatürde kendisine önemli bir yer bulmuştur. Neredeyse tamamının DVM özelinde yapıldığı çalışmalarda, belirli bir çekirdek fonksiyonu kümesinden sınıfları en iyi ayıran ayırma yüzeyinin belirlenmesi için en uygun çekirdek birleşiminin bulunması amaçlanmaktadır [15]. ÇÇÖ probleminin çözümü için şimdiye kadar, aralarında yarı-tanımlı programlama [16] ve ikinci-dereceden konik programlama [15] yaklaşımlarının da olduğu çeşitli stratejiler sunulmuştur. ÇÇÖ tasarımında ele alınan her bir çekirdekle oluşturulan sınıflandırıcılar alt/zayıf sınıflandırıcı olarak düşünülürse, bir ÇÇÖ problemine topluluk öğrenme (TÖ) stratejisiyle yaklaşılabilir. TÖ istatistiksel bir yöntem olup daha kararlı ve gürbüz bir sonuç elde etmek için birden fazla zayıf sınıflandırıcının/uzmanın bir problem üzerindeki

kararlarının birleştirilmesini amaçlar. Gösterilmiştir ki, ÇÇÖ, TÖ'nün özel bir durumudur [23]. Literatürde TÖ stratejilerinin ÇÇÖ probleminin çözümü için uygulamasına dair çalışmalar [24]-[26] olsa da, ÇFKD üzerine çalışmalarda diğer çekirdek yöntemlerinde olduğu gibi eksiklik vardır. Birleşimde kullanılan alt-çekirdeklerin nihai sonuçlarını bütünleştirmek için, tez kapsamında TÖ tekniğinin ana fikri kullanılmıştır. Farklı çekirdekler ve bu çekirdeklere ait farklı parametreler ile oluşturulmuş ÇFKD'lerin birleştirilmesi ile çekirdek ve parametresinin seçimi problemlerine de çözümler aranmıştır.

Hiperspektral görüntüleme sistemleri (HGS) yüksek-çözünürlüklü spektral veri sağlamak ve bu spektral bilgi sayesinde materyallerin uzaktan tanınmasına imkân vermektedir. Bununla birlikte, hiperspektral algılayıcılar tarafından üretilen bu yüksek-çözünürlüklü veri klasik analiz yöntemleri için yeni zorluklar getirmektedir. Bu zorlukların başında saklama, taşıma ve büyük dosyaların bilgisayarda işlenmesi sayılabilir. Bu kısıtların üstesinden gelmek için boyut indirgeme sıklıkla uygulanmıştır. Boyut indirgeme, bir yüksek boyutlu veriyi düşük boyutlu bir veriye getiren bir dönüşümdür [27]. Genel olarak konuşursak, hiperspektral veride önemli bir miktarda spektral fazlalık/gereksizlik mevcuttur. Buradan hareketle boyut azaltma ya da veri sıkıştırmanın bu görüntüler için uygun ve hatta gerekli olduğu söylenebilir.

Literatürde HGS ile alınmış görüntüler üzerinde uygulanmış birçok boyut azaltma tekniği bulunmakla birlikte (örn. [28] ve [29]), TBA bunların en popülerlerinden biridir. TBA, sürekli Karhunen-Loève dönüşümünün ayrık karşılığıdır. HGS uygulamalarında, TBA hesaplama için uygun bir yaklaşım önermekte ve istatistiksel anlamda ham verinin değişintisinin önemli oranda korunmasını sağlamaktadır [30]. Bu yöntemin, hiperspektral veri için teorik yetersizlikleri de [32], [33] bulunmakla birlikte, pratik uygulamalar TBA'nın halen sınıflandırma için kullanışlı sayılabileceğini göstermektedir [34], [35]. Bununla birlikte, TBA sadece ikinci-dereceden istatistik özellikler ile ilgilendiğinden, yöntemin karmaşık veriler için anlamlı sonuçlar üretebilme kabiliyeti sınırlı kalmaktadır. Bunların yanında, eğitici bir yöntem olmasından dolayı sınıf bilgisinin de kaybolma riski bulunmaktadır. FKD eğitici yapıları sayesinde pozitif sınıf (örn. hedef) ve negatif sınıfı (örn. arka plan karışıklığı) ayırt etmeye yarayan özvektörleri üretebilmektedir. Bu özvektörlerin seçimi ile oluşturulan filtreler, verinin boyutunu ayırt edici öznelikleri koruyarak azaltmaktadır [36]. FKD de tıpkı TBA gibi verinin yalnız doğrusal özelliklerini ortaya çıkardığından, hiperspektral görüntüler gibi yüksek boyutlu verilerde tatmin edici

bir performans gösterememesi olasıdır. Bu dezavantajı gidermek için, tez kapsamında, ÇFKD tabanlı hedef sınıf odaklı bir boyut indirgeme yöntemi [37] geliştirilmiştir. Yöntemin performansı TBA ve FKD ile karşılaştırılmıştır.

Daha önce belirtildiği gibi, FKD, tıpkı DVM gibi iki-sınıflı işleyen bir algoritmadır. Bu yapısıyla klasik sınıflandırma problemleri için uygun bir tekniktir. Yöntemin literatürdeki kullanımları incelendiğinde de, ya klasik haliyle iki-sınıflı sınıflandırma problemlerinde ya da iki-sınıflı yöntemlerin çoklu-sınıf problemlerde kullanılmasına imkân sağlayan bilinen yaklaşımlar yardımıyla çok-sınıflı problemlere uygulandığı görülmektedir. Hedef tespiti probleminin doğası gereği FKD yaklaşımının hedef tespiti uygulamalarına uygun olmadığı fark edilecektir. Başka bir deyişle, klasik bir eğitici hedef tespiti probleminde, öznitelikleri görece yüksek değişimli olan arka plan karışıklığına odaklanmak yerine hedefin referans bilgisini dikkate almak daha pratiktir. FKD özelinde, arka plan karışıklığını bir sınıf gibi kabul etsek bile, sınıf-içi değişiminin genel geçer bir doğrulama verisi oluşturmak için fazla yüksek olduğu kaçınılmaz bir gerçektir. Buradan hareketle, FKD tekniği, yalnız hedef sınıf eğitim örnekleri ile hedef sınıfı tanımlayan bir hale getirilmiş ve böylece tek-sınıflı çalışmasının önü açılmıştır. Eğitici hedef tespiti de genel anlamda bir tek-sınıflı sınıflandırma problemi olarak sayılabileceğinden, genel bir tek-sınıflı sınıflandırma problemi ve hiperspektral görüntülerde hedef tespiti görevi [38] için tek-sınıflı FKD yöntemi tez kapsamında önerilmiştir.

1.2 Tezin Amacı

Bu tez kapsamında, bir ayırma altuzay analizi (AAA) yaklaşımı olan FKD üzerinde durulmuştur. Sözü edilen yöntemin doğrusal olmayan versiyonu olan ÇFKD temel alınarak, içerisindeki çekirdek fonksiyonunun ve varsa fonksiyon parametresinin sınıflandırma ve tespit problemleri için uyarlanması, böylece iyileştirilmiş bir sınıflandırma/tespit performansının üretilmesi amaçlanmıştır.

Bu tezde, hem düşük hem de yüksek boyutlu verilerde çalışılmıştır. Yüksek boyutlu verilerde çalışırken karşılaşılan zorlukların önüne geçmek ve hedef tespiti için anlamlı öznitelikleri çıkarmak için ÇFKD tabanlı bir boyut azaltma algoritmasının geliştirilmesi de amaçlanmıştır.

Bunların yanında, hiperspektral hedef tespiti görevinin eğitici bir strateji ile FKD ile tamamlanması için, bir tek-sınıflı algoritmanın geliştirilmesi amaçlanmıştır. Böylece,

klasik bir hedef tespiti probleminde olduğu gibi, yalnız hedef sınıf referans özniteliklerinin kullanımıyla hedef-arka plan ayrımının sağlanması hedeflenmiştir.

1.3 Hipotez

Sınıflandırma ve tespit problemi örüntü tanıma, makine öğrenmesi ve bilgisayarla görü alanlarının önemli bir konusudur. Pasif algılama sistemleri ile elde edilmiş uzaktan algılama görüntüleri üzerinde sınıflandırma ve tespit ise askeri ve sivil birçok uygulamada kendine yer bulmaktadır. Bu uygulamaların yüksek doğrulukta ve kabul edilebilir sürelerde tamamlanabilmesi için uygun özniteliklerin çıkarılması gerekmektedir.

Makine öğrenmesi alanında son yıllarda artan şekilde kendisine yer bulan çekirdek tabanlı öğrenme, ham özniteliklerin giriş uzayından daha yüksek boyutlu bir uzaya taşınmasını ve bu yolla örüntüler arası ayrımın artırılmasını sağlamaktadır. Kullanılan çekirdeklerin sınıfların ayırt edici özelliklerinin artırılmasına yönelik geliştirilmesi yüksek doğrulukta çalışan bir örüntü tanıma görevi için oldukça önem taşımaktadır.

Bu tez çalışmasında, yukarıda bahsedilenler doğrultusunda, doğası gereği iki-sınıflı örüntüleri ayırmaya elverişli olan FKD yönteminin çekirdek versiyonunun (ÇFKD) daha yüksek performansta ayırma yapabilmesi için çekirdek ve varsa parametrelerinin uyarlanması gerçekleştirilmiştir. Ayrıca, yüksek boyutluluğun ortaya çıkardığı işlem yükü ve gereksiz bilginin azaltılması için yine ÇFKD tabanlı bir boyut azaltma algoritması geliştirilmiştir.

Bunların dışında, yalnız hedef sınıf özniteliklerine odaklanılan eğitici hedef tespiti uygulamalarında kullanılacak tek-sınıflı FKD-tabanlı yöntemler sunulmuştur. Önerilen yöntemlerin, literatürde mevcut olan klasik yaklaşımlara göre, problemde yer alan veriye ait daha az bilgi kullanarak daha gürbüz ve kararlı sonuçlar üretmesi öngörülmektedir.

HEDEF TESPİTİ VE SINIFLANDIRMA PROBLEMİNE GENEL BAKIŞ

Uzaktan algılama (UA) nesnelere fiziksel bağlantı kurmaksızın algılayıcı sistemleri kullanarak bilgi toplanması sürecini ifade etmektedir [39]. Kullanılan enerji kaynaklarına göre UA, aktif ve pasif algılama olmak üzere ikiye ayrılır. Pasif algılama yapan algılayıcılar dış ortamdan bir kaynağın gönderdiği ışınlar yardımıyla nesnelere yansıyan veya yayılan elektromanyetik radyasyonu algılar. Pasif algılayıcılarda alınan enerji, algılayıcının hassasiyetine göre değişen sayıda spektral banda bölünmekte ve kaydedilmektedir. Özellikle son yirmi yılda gelişen ve kullanımı yaygınlaşan hiperspektral algılayıcılar, ilgilenilen sahneye ait yüzlerce dar spektral bantta veri sağlamaktadırlar. Bu tür algılayıcılarda spektral bant aralığı o kadar dar olabilmektedir ki, neredeyse sürekli bir spektrumdan bahsedilebilir.


Bu bölümde öncelikle, hiperspektral görüntüleme ve bu görüntüleme sistemleri ile elde edilen görüntülerden özet olarak bahsedilecektir. Ardından, görüntü tanımada iki önemli kavram olan sınıflandırma ve tespit anlatılıp, bunlara yaklaşımda hiperspektral görüntü işlemedeki farklılığın teorik temeli ortaya konacaktır.

2.1 Hiperspektral Görüntüleme

Günümüzde, yeni kuşak uzaktan algılama sistemleri iklim değişimleri, kentleşme, orman yangınları, kıyı kesimleri, su kalitesi, toprak kayması gibi olayların incelenmesi, kirlilik yaratan etmenlerin belirlenmesi gibi yeryüzü olaylarını incelemek için birçok olanak sunmaktadır. Bu sorunların çözümü için kullanılan hiperspektral algılayıcılar yeryüzü arazisinin sınıflandırılması ve bu yapıya ait sınıfların belirlenmesinde yüksek başarımlar sunmaktadır. Hiperspektral görüntüleme sistemleri (HGS) elektromanyetik spektrumun

geniş bir aralığında yüksek çözünürlüklü spektral bilgi sağlamaktadır. Bu yüksek bilgi, farklı malzemelerin fiziksel ve kimyasal özelliklerine bağlı olarak, belirli dalga boylarında farklı karakterde elektromanyetik enerji yansıtma, soğurma ve salım özelliklerine sahip olması gerçeğinden kaynaklanmaktadır. Bu nedenle, sahne içerisindeki bölgelerin sınıflandırılması ve nesnelerin tanınması gibi UA uygulamalarında, hiperspektral görüntüler kullanılarak yüksek başarımlar elde edilebilmektedir [32]. Hiperspektral sınıflandırma, tanıma ve tespit yöntemlerinin; uzay araştırmaları, besin güvenliği ve kalitesi, adli tıp, biyoteknoloji, medikal bilimler, askeri ve savunma, maden arama ve işleme, ilaç üretimi gibi çeşitli alanlarda uygulamaları da bulunmaktadır.

Hiperspektral algılayıcılar aracılığıyla veri alma işlemi gerçekleştirildikten sonra elde edilen ham veri bir ön işlemeden geçirilerek hiperspektral küp adı verilen bir hale getirilir (Şekil 2.1). Hiperspektral küp verisinin dik kesitlerinin en küçük anlamlı parçasının (piksel) bir vektör olduğu görülecektir. Bu vektörün boyutu, algılayıcının kaydettiği spektral bant sayısı kadardır. Hiperspektral algılayıcıların sağladığı yüksek bilgi burada kendini göstermekte ve spektral vektörlerin nesnenin cinsine göre değişmesi beklenmektedir. Ön işleme aşamasında alınan spektrumun ışık kaynağından ve ortamdan bağımsız bir karaktere sahip olması için yansıma spektrumu elde edilir. Nesnelere hakkında ayırt edici bilgi taşıma özelliklerinden dolayı bu spektruma spektral imza denmektedir. Ayırt edici bilgi taşıyan bu vektörleri kullanarak görüntü üzerindeki alanları ve nesnelere birbirlerinden ayırt etmek ve sınıflandırmak mümkündür.



Şekil 2.1 Hiperspektral küp verisi ve spektral imza [40]

2.2 Hedef Tespiti ve Sınıflandırma Problemi

Önceki kısımda kalınan yerden sözü alırsak, eğer yansıma spektrumu yeterli oranda karakterize etme gücüne sahipse, sahnedeki materyalleri tanımlamak için kullanılabilir [41]. Sözü edilen bilgi taşıyan yansıma spektrumu ya da spektral imza; nesneye gelen enerjinin dalgaboyunun, λ , bir fonksiyonu olarak nesneden yansıma oranıdır.

$$\text{yansıma spektrumu } (\lambda) = \frac{\lambda \text{ bandında yansıyan ışım}}{\lambda \text{ bandında gelen ışım}} \quad (2.1)$$

Bu dönüşümün yapılma sebebini ve gözlenen ışım spektrası ile ilgili yansıma spektrası arasındaki farkı anlamak için atmosferin ve güneş spektrumunun etkisinin anlaşılması gerekmektedir. Kısaca özetlenecek olursa, eğer tüm dalgaboylarında atmosfer geçirgenliği aynı olsa ve de güneş spektrumu düz olsaydı gözlenen spektrum ile yansıma spektrumu aynı olacaktı [42]. Pratikte, algılayıcı tarafından alınan ışım spektrumu, güneşin ışım spektrumunun atmosferin geçirme fonksiyonu ve gözlenen noktanın yansıma spektrumu tarafından değiştirilmiş halidir.

Bir sahne hakkında bilgi, sürekli uzayın, dalga boyunun ve zaman değişkenlerinin bir fonksiyonu olarak görülebilir [30]. Bununla birlikte, pratikte algılayıcıların uzamsal, spektral, radyometrik ve zamansal çözünürlükleri kısıtlıdır. Bu kısıtlar, sahneden gelen ışımın sonlu/sınırlı bir çözünürlükte kaydedilmesine neden olur. Algılayıcının uzamsal çözünürlüğü görüntülenen sahnede yer alan nesnelerin çevrelerinden ne kadar ayrılabilir olduğunu belirler. Başka bir deyişle, kaydedilen sahnede görülebilen en küçük ayrıntı bu çözünürlük cinsinin bir göstergesidir. Spektral çözünürlük, kaydedilen dalga boyları arasındaki farkla hesaplanır. Algılayıcı tarafından ölçülen ışımın tanımlanması için kullanılan bit sayısı ise radyometrik çözünürlük ile ifade edilir. Zamansal çözünürlük ise adından da tahmin edileceği üzere algılayıcının bir sahne hakkında yeni bir veri oluşturmak için hangi zaman aralıklarıyla ölçümler yaptığıyla alakalıdır.

UA ile elde edilmiş spektral bilgi içeren görüntüler çeşitli amaçlar için kullanılsa da mineral tespiti ve yeryüzü örtüsünün belirlenmesi gibi doğal çevrenin incelenmesine dayanan uygulamalar önemli bir yer tutmaktadır. Bu tür uygulamalarda, ilgilenilen doğal materyallerin belirli bir şekli olmadığından (örneğin bir buğday tarlasının sınırları), şekil bilgisinin insan-yapımı bir nesnenin gözlendiği duruma göre minimum tutulması yerinde olacaktır. Hiperspektral görüntü işlemede diğer bir yaklaşım benzer piksellerin (en küçük uzamsal birimler) sınıflandırılması veya gruplanmasına yöneliktir. Bu tür durumlarda,

genellikle, geniş bir alanda ve görece yüksek sayıda pikselle uğraşılmakta ve bazı durumlarda yanlış sınıflandırılan örnek sayısının çokluğu çok da önemli bir etki yapmamaktadır. Örneğin bir sahne üzerinde, belirli bir bitki türünün var olup olmadığının araştırıldığı bir uygulamada, o bitki türünü içeren tüm arazinin tespiti yerine belirli bir bölümünün tespiti amaca ulaşmada yeterli bir kıstas olacaktır. Bu durumun aksine, bir hedef tespiti uygulamasında, görece az sayıda ve genellikle sabit bir şekle sahip nesnelerin belirlenmesi istenmektedir. Sınıflandırma için kullanılan tekniklerin, hedef tespiti için uygulanabilir olmamasının temelde iki nedeni vardır. İlki, bir sahnedeki hedeflerin sayısının hedef sınıfın istatistiksel özelliklerinin kestirimi için genellikle yetersiz sayıda olmasıdır. İkincisi ise, algılayıcının bir özelliği olarak, uzamsal çözünürlüğün hedefi etrafından ayıramayacak kadar ya da birkaç pikselle temsil edebilecek kadar düşük olmasıdır. Burada yeri gelmişken, elde edilen sahnede bir nesnenin, bir pikselle dahi temsil edilemeyecek kadar çözünmemiş olabileceği söylenmelidir. Literatürde bu tür durumlar, hiperspektral ayrıştırma ya da piksel-altı hedef tespiti başlıklarında genişçe incelenmekte ve esasen bu tezin kapsamına girmemektedir.

Hiperspektral algılayıcıların gelişiminde uzamsal ve spektral çözünürlüğün bir ödünleşim içerisinde olduğu, daha net bir ifadeyle, spektral çözünürlüğün gelişmesinin uzamsal bilginin zayıflamasına yol açtığı görülmektedir. Buradan hareketle, hiperspektral görüntü işleme uygulamalarında genel olarak spektral bilginin kullanımının uzamsal bilgidен daha güvenli ve anlamlı olduğu ifade edilebilir [43]. Örneğin, yine insan-yapımı bir nesnenin klasik renkli görüntülerde tanımlanması probleminde, nesnenin engel arkasında kalması ya da kamuflejli olması durumunda şekil bilgisinin (uzunluk, genişlik gibi) yalın halde güvenilir olmayacağı açıktır. Bu tür bir durum için, hiperspektral görüntülemenin sağladığı spektral bilginin önemi ve gerekliliği yadsınamaz derecesindedir.

Spektraları belirli bir spektral forma sahip piksellerin tanımlanması problemi ile birçok uygulamada karşılaşılır. Bu probleme yaklaşırken; bir spektra yalnız bir materyali temsil eder mi, herhangi bir materyalin spektrası farklı zaman ve şartlarda değişir mi ve iki spektranın aynı materyale ait olup olmadığına nasıl karar veririz gibi önemli ve zorlu sorular araştırmacıların önüne çıkmaktadır. Bu kritik sorulara cevaplar aranırken UA, Öklid geometrisi, istatistik, işaret ve görüntü işleme gibi alanlar ve araçlar sürece dâhil edilmektedir [32]. Algılayıcı tarafından kaydedilen ışınma verisinin ya da üretilen yansıma verisinin bir küp verisi olarak ifade edilebileceği belirtilmişti. Bu küpe farklı bir açıdan

yaklaşırsak, aynı veri d -boyutlu Öklid uzayında, \mathbb{R}^d , dağılmış noktalar olarak görülebilir. Burada, her bir nokta bir piksele karşılık gelmekte ve d spektral bantların sayısını temsil etmektedir. Her spektral bant uzayın bir eksenine karşılık gelmektedir. Dolayısıyla her bir piksel, T matris devriğini göstermek üzere d -boyutlu bir vektörle sunulabilir.

$$\mathbf{x} = [\mathbf{x}_1, \dots, \mathbf{x}_d]^T \quad (2.2)$$

Eğer her materyal tek bir deterministik spektrum ile karakterize edilseydi, iki spektra arasındaki mesafe Eşitlik 2.3 ile verilen Öklid mesafe ölçütü kullanılarak ölçülebilirdi.

$$\|\mathbf{x} - \mathbf{y}\| = \sqrt{\sum_1^d (\mathbf{x}_i - \mathbf{y}_i)^2} \quad (2.3)$$

Öklid uzaklığı dışında yine popüler bir teknik olan spektral açı haritalayıcısı (SAH) da kullanılabilir.

$$\theta_{\mathbf{x},\mathbf{y}} = \arccos\left(\frac{\langle \mathbf{x}, \mathbf{y} \rangle}{\|\mathbf{x}\| \|\mathbf{y}\|}\right) \quad (2.4)$$

Burada, $\langle \mathbf{x}, \mathbf{y} \rangle$ işlemi \mathbf{x} ve \mathbf{y} vektörlerinin iç-çarpımıdır. Eşitlikler 2.3 ve 2.4 ile verilen iki metrik hiperspektral veri işlemede sıkça kullanılmaktadır.

Tespit algoritmalarının tasarımında ve uygulanmasında hedef ve hedef-olmayan sınıf için anlamlı olasılık dağılımlarının oluşturulması tespit probleminin çözümünü kolaylaştıran bir etmendir. Tespit probleminin genel çerçevesini istatistiksel bir yaklaşım olan ikili hipotez testi ile çizebiliriz. Klasik tespit ediciler arasında olabilirlik oranı (OO) testi tabanlı olanların belirli avantajları vardır. Bu avantajlardan ilki, OO testlerinin yanlış karar riskini azaltmasıdır. İkincisi ise, OO testleri, tespit edici sistemleri çeşitli performans ölçütleri açısından optimum olmaya yönlendirmektedir. Teorik analiz için, spektralar belirli olasılık dağılımlarına sahip rasgele vektörler olarak düşünülebilir. Verilen bir \mathbf{x} spektrumunu için iki hipotez arasında karar verilmek istenirse:


H_0 : hedef yok

H_1 : hedef var (2.5)

İki hipotez altında koşullu olasılık yoğunluk fonksiyonları $p(\mathbf{x}|H_0)$ ve $p(\mathbf{x}|H_1)$ olsun. O halde OO Eşitlik 2.6 ile verilir. Eğer $\mathcal{L}(\mathbf{x})$ belirli bir eşik değerini aşarsa, hedef var hipotezi doğru olarak kabul edilir.

$$\mathcal{L}(\mathbf{x}) = \frac{p(\mathbf{x}|\text{hedef var})}{p(\mathbf{x}|\text{hedef yok})} \quad (2.6)$$

Genel olarak, OO testi en muhtemel hipotezi doğru olarak alır. Bir tespit sisteminde, tespit hataları sayısını düşük, doğru kararların sayısını yüksek tutan eşik değerinin seçimi önemli bir görevdir. Hedef tespiti olasılığının yüksek olması için düşük bir eşik, yanlış alarm olasılığının düşük olması için ise yüksek bir eşik değeri seçmek sezgisel olarak düşünülebilir. Yanlış alarm olasılığı ile tespit olasılığı arasındaki bu ödünleşim, alıcı çalışma karakteristiği (AÇK) adı verilen ve karar vericinin etkinliğini gösteren eğriler ile açıklanır. Değişik türlerde AÇK eğrileri olsa da, en sık kullanılanında, tespit olasılığına karşı yanlış alarm oranı tüm olası eşik değerleri için çizdirilir. Pratik hedef tespiti uygulamalarında genel amaç, yanlış alarm olasılığını önceden belirli bir değer altında tutmaya çalışırken tespit olasılığının yükseltilmeye çalışılmasıdır. Yine pratik hedef tespiti uygulamalarında, hedefe ait örneklerin (pikseller) küçük olduğu, bu durumun da hedefin yoğunluk parametrelerinin kestirimini oldukça zorlaştırdığı görülmektedir. Bu kısıt, hedef tespiti sınıflandırmadan ayıran temel nedendir. Bu iki fenomen arasındaki farklılıklar Şekil 2.2’de özetlenmiştir. Teoride hedef ve arka plan sınıflarının olasılık yoğunlukları biliniyorsa, sınıflandırma ve tespit aynı hipotez testleri ile çözülebilir. Buna karşın, pratikte ise, her sınıfın istatistiklerinin veriden kestirimi gerekebilir. Hedef sınıfın veri üzerinde seyrek olması bu kestirimi zorlaştıran sebeplerin başında gelmektedir.



Şekil 2.2 Hedef tespiti ve sınıflandırmanın teorisi ve pratik durum

Hiperspektral veri işlemede her spektral bandın bir boyuta karşılık geldiği belirtilmişti. Bu yüksek boyutlu veri ile çalışmanın, getirdiği işlem yükünün dışında da bazı zorlukları vardır. Bir sınıf ile ilgili eğitim sonuçlarının genellenebilirliği, mevcut eğitim örnekleri sayısının veri boyutundan düşük olduğu durumlarda düşüktür. Bu istenmeyen durum, hiperspektral veri için sıkça karşılaşılabilecek bir zorluktur ve eğitim verisi üzerinde yüksek bir performans alınsa da, test verisinde tatmin edici bir sonuç üretilmemesine yol açar. Bu problem, UA literatüründe Hughes etkisi [44] ya da boyutluluğun laneti [45] olarak geçmekte ve hiperspektral verilerin kullanıldığı ilk dönemlerden beri üzerinde

durulmaktadır. Makine öğrenmesi teknikleri ile bu problemin çözümü için çeşitli yollar aransa da, hiperspektral verinin boyutunun azaltılmaya çalışıldığı öznelik çıkarma ve seçme teknikleri literatürde geniş bir yer tutmaktadır [46]. Hedef sınıf açısından konu ele alınırsa, verinin boyutu azaltılmaya çalışılırken hedefin ayırt edici bilgisinin korunması nihai tespit edici sistemin performansı için hayattır denilebilir. Bu tez kapsamında, hiperspektral verilerin yüksek boyutluluğundan kurtulunurken ayırt edici sınıf bilgisinin korunmaya çalışıldığı bir algoritma da gerçekleştirilmiştir (Bkz. Bölüm 4).



DOĞRUSAL VE DOĞRUSAL OLMAYAN FUKUNAGA-KOONTZ DÖNÜŞÜMÜ

Bu bölümde öncelikle, Fukunaga-Koontz Dönüşümü (FKD) ve çekirdek FKD (ÇFKD) yöntemlerinin teorik altyapısı ortaya konulmuştur. Ardından, literatürde çekirdek tabanlı öğrenme başlığında yer alan popüler tekniklerden kompozisyonel çekirdek birleşimi (KÇB), bileşik çekirdekler (BÇ) ve çoklu-çekirdek öğrenmesi (ÇÇÖ) yaklaşımlarından bahsedilmiştir. Bu yaklaşımlardan her birinin FKD algoritmasına eklenmesiyle oluşturulmuş algoritmalar ayrı başlıklar altında incelenmiştir. ÇFKD yönteminin oluşturulmasında gerekli olan çekirdek fonksiyonu parametresinin, verilen örüntüleri uygun biçimde ayıracak şekilde seçilmesi önemli bir problemdir. Bu probleme getirilen özgün bir çözüm bu bölümü sonlandırmaktadır.

3.1 Fukunaga-Koontz Dönüşümü (FKD)

FKD [4] bir öznitelik seçme ve sıralama yöntemi olarak önerilmiştir. FKD çıkış noktası olarak bir örüntü hakkında yüksek bilgiye sahip olan bir özvektörün diğer örüntü ile ilgili önemsiz bilgi taşıdığı fikrine dayanmaktadır. Buradan hareketle, FKD iki sınıflı modeller için iyi bir ayırma kuralı sağlamaktadır. Pozitif (hedef) ve negatif (hedef-değil) olarak adlandırılan ortalanmış iki küme ele alalım, $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_M]$ ve $\mathbf{Y} = [\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_N]$, her bir \mathbf{x}_i ve $\mathbf{y}_j \in \mathbb{R}^d$ uzayında bir öznitelik vektörüdür. Sıfır ortalamalı hale getirilmiş bu kümelere karşılık gelen kovaryans matrisleri sırasıyla $\mathbf{\Sigma}_X = \mathbf{X}\mathbf{X}^T$ ve $\mathbf{\Sigma}_Y = \mathbf{Y}\mathbf{Y}^T$ olsun. Bu kovaryans matrislerinin toplamının özayırıştırması Eşitlik 3.1’de verilmiştir.

$$\mathbf{\Sigma} = \mathbf{\Sigma}_X + \mathbf{\Sigma}_Y = \mathbf{V}\mathbf{\Lambda}\mathbf{V}^T \quad (3.1)$$

Eşitlik 3.1’de, \mathbf{V} , toplam matrisinin özvektör matrisini, $\mathbf{\Lambda}$ ise diyagonal elemanları bu özvektörlere karşılık özdeğerlerden oluşan matrisi temsil etmektedir. Bir dönüşüm

operatörü $\mathbf{P} = \mathbf{V}\mathbf{\Lambda}^{-1/2}$ oluşturulur ve giriş verilerinin dönüştürülmesinde kullanılır: $\hat{\mathbf{X}} = \mathbf{P}^T \mathbf{X} = [\hat{\mathbf{x}}_1, \hat{\mathbf{x}}_2, \dots, \hat{\mathbf{x}}_M]$ ve $\hat{\mathbf{Y}} = \mathbf{P}^T \mathbf{Y} = [\hat{\mathbf{y}}_1, \hat{\mathbf{y}}_2, \dots, \hat{\mathbf{y}}_N]$. Yeni kovaryans matrisleri Eşitlik 3.2 ile ifade edilebilir.

$$\mathbf{\Sigma}_{\hat{\mathbf{X}}} = \hat{\mathbf{X}}\hat{\mathbf{X}}^T = \mathbf{P}^T \mathbf{X}\mathbf{X}^T \mathbf{P} = \mathbf{P}^T \mathbf{\Sigma}_{\mathbf{X}} \mathbf{P} \text{ ve } \mathbf{\Sigma}_{\hat{\mathbf{Y}}} = \hat{\mathbf{Y}}\hat{\mathbf{Y}}^T = \mathbf{P}^T \mathbf{Y}\mathbf{Y}^T \mathbf{P} = \mathbf{P}^T \mathbf{\Sigma}_{\mathbf{Y}} \mathbf{P} \quad (3.2)$$

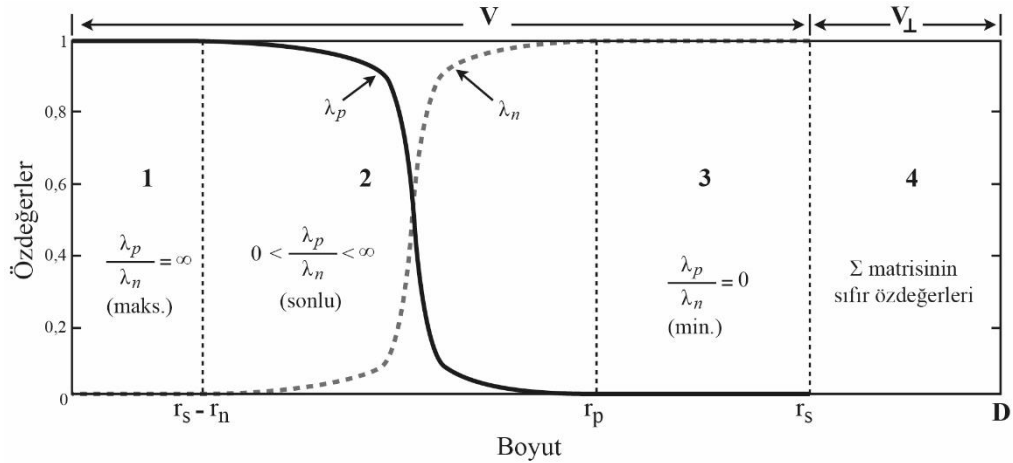
Bu matrislerin toplamı birim matrise (\mathbf{I}) eşittir. Böylece FKD yönteminin temel fikri ortaya çıkmış olur.

$$\hat{\mathbf{\Sigma}} = \mathbf{\Sigma}_{\hat{\mathbf{X}}} + \mathbf{\Sigma}_{\hat{\mathbf{Y}}} = \mathbf{P}^T (\mathbf{\Sigma}_{\mathbf{X}} + \mathbf{\Sigma}_{\mathbf{Y}}) \mathbf{P} = \mathbf{I} \quad (3.3)$$

$\mathbf{\Sigma}_{\hat{\mathbf{X}}}$ ve $\mathbf{\Sigma}_{\hat{\mathbf{Y}}}$ aynı özvektör alt kümesini paylaşmaktadır. Daha net bir ifadeyle, eğer \mathbf{v}_i özvektörü $\mathbf{\Sigma}_{\hat{\mathbf{X}}}$ matrisinin λ_i özdeğerine karşılık geliyorsa, $(1 - \lambda_i)$ de $\mathbf{\Sigma}_{\hat{\mathbf{Y}}}$ matrisinin aynı özvektörüne karşılık gelmektedir. Bu durumun önemli bir sonucu olarak; iki örüntünün kovaryans matrisleri aynı özvektör alt uzayını kapsar, bununla birlikte pozitif sınıfı iyi temsil eden bir özvektör diğer sınıf için önemsiz bir karakteristiği tutmaktadır denilebilir [5], [9]. Buradan hareketle, FKD özellikle iki-sınıflı örüntülerde ayırma/sınıflandırma probleminin çözümünde kullanışlı bir araçtır [5], [47]. Bu çıkarımlar aşağıda özetlenmiştir:

$$\hat{\mathbf{\Sigma}}_{\mathbf{X}} \mathbf{v}_i = (\mathbf{I} - \hat{\mathbf{\Sigma}}_{\mathbf{Y}}) \mathbf{v}_i = \lambda_i \mathbf{v}_i \quad (3.4)$$

$$\hat{\mathbf{\Sigma}}_{\mathbf{Y}} \mathbf{v}_i = (\mathbf{I} - \lambda_i) \mathbf{v}_i \quad (3.5)$$



Şekil 3.1 Tüm veri uzayının FKD ile dört alt uzaya bölünmesi

İki sınıf aynı özvektör alt uzayını kapsadığından, ayırma/sınıflandırma tek bir alt uzay üzerinde gerçekleştirilebilir. Zhang ve Sim [48] bu alt uzayı öz niteliklerin oranına göre belirlenmiş üç alt bölgeye ayırmıştır. Böylece tüm veri, $\mathbf{\Sigma}_{\mathbf{X}}$ ve $\mathbf{\Sigma}_{\mathbf{Y}}$ 'nin ortak sıfır uzayları

ile birlikte dört parçanın birleşimi olarak düşünülebilir. Alt uzayın farklı karakterdeki bölgelerini gösteren ve [48] ile verilen çalışmadan uyarlanan çizim Şekil 3.1’de verilmiştir. Şekil 3.1’de, \mathbf{V}_\perp , \mathbf{V} ’nin dikgen tamamlayıcısıdır. r_p , r_n ve r_s sırasıyla Σ_X , Σ_Y ve Σ matrislerinin rankını göstermektedir.

Bu bölgeler ve özellikleri aşağıda verilmiştir:

- Alt uzay 1 (A_1). Bu alt uzay, pozitif sınıf özdeğerlerinin 1’e eşit olduğu, $\lambda_p = 1$, negatif sınıf özdeğerlerinin ise 0’a eşit olduğu, $\lambda_n = 0$, duruma karşılık gelen özvektörleri tutar. Dolayısıyla bu alt uzayda özdeğerlerin oranı sonsuza eşittir, $\lambda_p/\lambda_n = \infty$.
- Alt uzay 2 (A_2). Bu alt uzayda özdeğerler 0 ve 1 arasındadır, $0 < \{\lambda_p, \lambda_n\} < 1$. Bu nedenle, özdeğerlerin oranı bu bölgede sonlu ve A_1 bölgesindeki orandan küçüktür. Bu bölge, daha da ileri gidilerek, iki alt-bölgeye de ayrılabilir. Bu ayırma için sınır, özdeğerlerin eşit olduğu, $\lambda_p = \lambda_n = 0.5$, nokta olacaktır. Sınırın solunda özdeğerlerin oranı $1 < \lambda_p/\lambda_n < \infty$; sağında ise $0 < \lambda_p/\lambda_n < 1$ aralığında verilir.
- Alt uzay 3 (A_3). Bu bölgede özdeğer oranı, $\lambda_p = 0$ ve $\lambda_n = 1$ olduğundan minimum değerine eşittir.
- Alt uzay 4 (A_4). Bu bölge Σ matrisinin sıfır özdeğerlerini kapsar.

Bir \mathbf{z} test vektörünün sınıfını belirlemek için ikinci dereceden ilinti süzgeçleri (İİS, *quadratic correlation filters* (QCF)) yaklaşımından faydalanılır [3], [6], [49]. Test vektörüne ait katsayı matrisi \mathbf{Q} çıkışları $\mathbf{z} \in \mathbf{X}$ için pozitif veya büyük, $\mathbf{z} \in \mathbf{Y}$ için negatif veya küçük olacaktır. $\Theta = [\mathbf{v}_1 \ \mathbf{v}_2 \ \dots \ \mathbf{v}_l]$ matrisini, sütunları $\Sigma_{\hat{\mathbf{x}}}$ ’nin azalan sıradaki özdeğerlerine $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_l \geq 0$ karşılık gelen özvektör matrisi olarak alalım. Θ kümesinden seçilen ilk l_1 özvektör pozitif sınıfı en iyi temsil ederken, son l_2 özvektör negatif sınıf için anlamlı bilgiyi taşıyacaktır. Bu özvektörlerle gerilen iki alt uzay:

$$\Theta_1 = [\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_{l_1}] \quad (3.6)$$

$$\Theta_2 = [\mathbf{v}_l, \mathbf{v}_{l-1}, \dots, \mathbf{v}_{l-l_2+1}] \quad (3.7)$$

Test vektörü öncelikle \mathbf{P} dönüşüm operatörü aracılığıyla dönüştürülür ($\hat{\mathbf{z}} = \mathbf{P}^\top \mathbf{z}$), ardından Θ_1 (pozitif) ve Θ_2 (negatif) alt uzaylarına sırasıyla yansıtılır ($\mathbf{S}_1 = \Theta_1^\top \hat{\mathbf{z}}$ ve $\mathbf{S}_2 =$

$\Theta_2^T \hat{\mathbf{z}}$). Buradan, FKD-İİS tabanlı modele göre Eşitlik 3.8 ile verilen çıkış, yöntemin karar vermesi için kullanılabilir [49].

$$y_{\text{out}} = \mathbf{S}_1^T \mathbf{S}_1 - \mathbf{S}_2^T \mathbf{S}_2 \quad (3.8)$$

Eğer \mathbf{z} test vektörü pozitif sınıfa ait ise y_{out} pozitif ya da büyük, diğer sınıfa ait ise negatif ya da küçük olacaktır. Özetle, bir karar kuralı olarak Eşitlik 3.8 örüntü tanıma problemlerinde ayırma/sınıflandırma görevi için kullanılabilir.

3.2 Çekirdek Fukunaga-Koontz Dönüşümü (ÇFKD)

FKD güçlü bir iki-sınıflı sınıflandırma yaklaşımı olmasının yanında yalnızca ikinci-dereceden ilişkileri çıkardığından daha yüksek derecede özellikleri kavramada yetersizdir. Bu kısıtın üstesinden gelmek için, FKD [5], [9], çalışmalarında çekirdek dönüşümü yaklaşımıyla doğrusal olmayan hale getirilmiştir. Bir ϕ eşleme kuralı [50] yardımıyla, giriş verisi $\mathbf{x} \in \mathbb{R}^d$ daha yüksek dereceden bir öznitelik (Hilbert) uzayına yansıtılır; $\phi: \mathbf{x} \in \mathbb{R}^d \rightarrow \phi(\mathbf{x}) \in \mathbb{H}$. Sınıflandırma algoritması yüksek dereceli \mathbb{H} uzayında sadece iç-çarpımlara ($\langle \phi(\mathbf{x}_i), \phi(\mathbf{x}_j) \rangle$) ihtiyaç duyduğundan ϕ eşleme fonksiyonunun tam olarak bilinmesi gerekli değildir. Gösterilebilir ki, bu iç-çarpıma karşılık gelen bir fonksiyon her zaman vardır [51].

$$k(\mathbf{x}_i, \mathbf{x}_j) = \langle \phi(\mathbf{x}_i), \phi(\mathbf{x}_j) \rangle \quad (3.9)$$

Eşleme fonksiyonunun kullanıldığı adımın atlanması ve bunun yerine öznitelik uzayında iç-çarpıma karşılık gelen bir pozitif yarıtanımlı fonksiyon kullanılması sebebiyle bu işleme çekirdek hilesi, kullanılan fonksiyona ise çekirdek fonksiyonu denilmektedir. Literatürde tanımlanmış çok sayıda çekirdek fonksiyonu yer almakla birlikte en bilinenlerinden biri Öklid uzaklığı tabanlı Gauss tipi radyal tabanlı fonksiyondur (RTF) [51]; $k(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\|\mathbf{x}_i - \mathbf{x}_j\|^2 / 2\sigma^2)$, $\sigma \in \mathbb{R}^+$.

Pozitif ve negatif sınıflara ait giriş vektörlerinin çekirdek matrisleri hesaplanır. Pozitif sınıf için örnek bir çekirdek matrisi formu Eşitlik 3.10'da verilmiştir.

$$\mathbf{K} = \begin{bmatrix} k(\mathbf{x}_1, \mathbf{x}_1) & \cdots & k(\mathbf{x}_1, \mathbf{x}_M) \\ \vdots & \ddots & \vdots \\ k(\mathbf{x}_M, \mathbf{x}_1) & \cdots & k(\mathbf{x}_M, \mathbf{x}_M) \end{bmatrix} \quad (3.10)$$

Çekirdek matrisleri hesaplandıktan sonra, ÇFKD klasik FKD gibi sürdürülür. Σ^K giriş çekirdek matrislerinin (Σ_X^K ve Σ_Y^K) toplamı olsun. Toplam matrisinin özayırıştırması:

$$\Sigma^K = \Sigma_X^K + \Sigma_Y^K = \Phi \Lambda^K \Phi^\top \quad (3.11)$$

Φ matrisinin sütunları Λ^K 'da yer alan özdeğerlere karşılık gelen özvektörlerdir. Burada FKD'den farklı olarak belirtilmesi gereken nokta pozitif ve negatif sınıf eğitim örnekleri sayısının aynı olması gerekliliğidir. Doğrusal sürümde olduğu gibi bir dönüşüm operatörü $\mathbf{P} = \Phi(\Lambda^K)^{-1/2}$ oluşturulur ve $\mathbf{P}^\top \Sigma^K \mathbf{P} = \mathbf{I}$ elde edilir.

$$\widehat{\Sigma} = \widehat{\Sigma}_X + \widehat{\Sigma}_Y = \mathbf{P}^\top (\Sigma_X^K + \Sigma_Y^K) \mathbf{P} = \mathbf{I} \quad (3.12)$$

Bir \mathbf{z} test vektörünün sınıfını belirlemek için öncelikle ϕ eşleme fonksiyonundan geçirilmesi gerekmektedir: $\phi: \mathbf{z} \rightarrow \phi(\mathbf{z}) = \mathbf{z}^\phi$. Dönüşüm operatörü kullanılarak $\widehat{\mathbf{z}}^\phi = \mathbf{P}^\top \mathbf{z}^\phi$ elde edilir. Buradan, Eşitlik 3.8 benzeri bir karar kuralı yazılmaya çalışıldığında eşleme kuralının açık halinin bilinmesi gerekliliği ile karşı karşıya kalınacaktır. Oysa literatürde sıklıkla kullanılan birçok çekirdek fonksiyonu için karşılık geldiği eşleme kuralının matematiksel formunun bilinmesi mümkün değildir. Bu durumdan çekirdek hilesiyle kurtulmak için öncelikle Σ_X^K merkezleştirilir [52]:

$$\widetilde{\Sigma}_X^K = \Sigma_X^K - \mathbf{I}_M \Sigma_X^K - \Sigma_X^K \mathbf{I}_M + \mathbf{I}_M \Sigma_X^K \mathbf{I}_M \quad (3.13)$$

Burada \mathbf{I}_M tüm elemanları $1/M$ olan $M \times M$ boyutlu bir matristir. $\widetilde{\Sigma}_X^K$ matrisinin en büyük l özdeğerine $(\lambda_1^K, \lambda_2^K, \dots, \lambda_l^K)$ karşılık gelen özvektörler $(\theta_1^K, \theta_2^K, \dots, \theta_l^K)$ seçilir. Pozitif sınıfın eğitim örnekleri için test vektörü \mathbf{z} 'nin i . öz niteliği Eşitlik 3.14 ile bulunur.

$$f_i = (1/\sqrt{\lambda_i^K}) \theta_i^{K\top} [k(\mathbf{x}_1, \mathbf{z}), k(\mathbf{x}_2, \mathbf{z}), \dots, k(\mathbf{x}_M, \mathbf{z})], \quad i = 1, \dots, l \quad (3.14)$$

Bu işlemlerin ardından, elde edilen öz nitelik vektörü $\mathbf{f} = [f_1, f_2, \dots, f_l]$, $\widehat{\mathbf{f}} = \mathbf{P}^\top \mathbf{f}$ ile dönüştürülür. Son olarak, $\widehat{\mathbf{f}}$ pozitif ve negatif grupların özvektörleriyle üretilen alt uzaylara aktarılır:

$$\mathbf{Y}_1 = \mathbf{R}_1^\top \widehat{\mathbf{f}} \quad (3.15)$$

$$\mathbf{Y}_2 = \mathbf{R}_2^\top \widehat{\mathbf{f}} \quad (3.16)$$

Burada, \mathbf{R}_1 ve \mathbf{R}_2 sırasıyla pozitif ve negatif eğitim kümesini temsil eden alt uzaylardır. $\mathbf{R} = [\mathbf{v}_1 \ \mathbf{v}_2 \ \dots \ \mathbf{v}_l]$ matrisini, sütunları $\widetilde{\Sigma}_X^K$ 'nin azalan sıradaki özdeğerlerine $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_l \geq 0$ karşılık gelen özvektör matrisi olarak alalım. \mathbf{V} kümesinden seçilen ilk l_1 özvektör pozitif sınıfı en iyi temsil edecek şekilde seçilirken, son l_2 özvektör negatifler için seçilir. ÇFKD'ye ait bir karar kuralı

$$y_{\text{out}} = \mathbf{Y}_1^T \mathbf{Y}_1 - \mathbf{Y}_2^T \mathbf{Y}_2 \quad (3.17)$$

ile yazılır. Eğer \mathbf{z} test vektörü pozitif sınıfa ait ise y_{out} pozitif ya da büyük, tersi durumda negatif ya da küçük olacaktır.

3.2.1 Kompozisyonel Çekirdek Birleşimi (KÇB)

Farklı her çekirdek ham verinin farklı öznitelik uzaylarındaki iç-çarpımlarına karşılık geldiğinden, çekirdek ve parametrelerinin seçimi konusu araştırmacıların ilgisini çekmiştir. Yapılan çalışmalar, tek bir çekirdek tipinin en iyi olamayacağını göstermiştir [11]. Buradan hareketle, çeşitli çekirdek birleşimi yöntemleri geliştirilmekle birlikte, bu yaklaşımlar genel olarak çekirdek fonksiyonlarının ağırlıklandırılması esasına göre çalıştığından, orijinal fonksiyonun etkisinin kaybolma riski bulunmaktadır. İlginç bir fikir olarak [20] çalışmasında, orijinal bilginin korunması amacıyla orijinal çekirdek matrislerinin bir kompozisyonu önerilmiştir. Farklı öznitelik uzaylarına götüren iki eşleme fonksiyonu ϕ_f ve $\phi_{f'}$ olmak üzere kompozisyonel birleşim Eşitlik 3.18 ile tanımlanır [20].

$$k_{f,f'}(\mathbf{x}_i, \mathbf{x}_j) \stackrel{\text{def}}{=} \langle \phi_f(\mathbf{x}_i), \phi_{f'}(\mathbf{x}_j) \rangle \quad (3.18)$$

$$\stackrel{\text{def}}{=} \int k_f^{1/2}(\mathbf{x}_i, \mathbf{z}) k_{f'}^{1/2}(\mathbf{x}_j, \mathbf{z}) d\mathbf{z}$$

RTF çekirdek fonksiyonunun karekökü:

$$k_f^{1/2}(\mathbf{x}_i, \mathbf{z}) = \left(\frac{4}{\pi \sigma_f^2} \right)^{\frac{d}{4}} \exp(-2 \|\mathbf{x}_i - \mathbf{z}\|^2 / \sigma_f^2) \quad (3.19)$$

Eşitlik 3.19 kullanılarak iki çekirdek matrisinin karışımı:

$$\mathbf{K}_{f,f'}(\mathbf{x}_i, \mathbf{x}_j) = \left(\frac{2\sigma_f\sigma_{f'}}{\sigma_f^2 + \sigma_{f'}^2} \right)^{\frac{d}{2}} \exp\left(\frac{-2\|\mathbf{x}_i - \mathbf{x}_j\|^2}{\sigma_f^2 + \sigma_{f'}^2} \right) \quad (3.20)$$

Buradan, kompozisyonel çekirdek matrisi (\mathbf{K}_{komp}) Eşitlik 3.21 ile yazılır.

$$\mathbf{K}_{\text{komp}} = \begin{bmatrix} \mathbf{K}_{1,1} & \cdots & \mathbf{K}_{1,h} \\ \vdots & \ddots & \vdots \\ \mathbf{K}_{h,1} & \cdots & \mathbf{K}_{h,h} \end{bmatrix} \quad (3.21)$$

Eşitlik 3.21 ile verilen yeni çekirdek matrisinin diyagonal elemanları orijinal çekirdek matrislerine karşılık gelmektedir. Kullanılan orijinal çekirdek fonksiyonlarının ve ilgililenilen veriye ait örneklerin sayısı sırasıyla h ve m olmak üzere, yeni matrisin

boyutları $(h \times m) \times (h \times m)$ olacaktır. Kompozisyonel çekirdek birleşimi (KÇB) durumunda DVM yönteminin ilgilendiği optimizasyon probleminin yeniden formülize edilmesi ile ilgili ayrıntılı bilgi için [20] ile verilen çalışma incelenebilir.

3.2.2 Bileşik Çekirdekler (BÇ)

Bileşik çekirdekler (BÇ) kavramına geçmeden önce çekirdek fonksiyonlarından bahsetmek yerinde olacaktır. Çekirdek-tabanlı öğrenme uygulamalarında, Mercer'in koşulunu sağlayan ve genellikle $k(\cdot, \cdot)$ ile verilen herhangi bir fonksiyon kullanılabilir.

Mercer Çekirdeği. X herhangi bir giriş uzayı ve $k: X \times X \rightarrow \mathbb{R}$ bir simetrik fonksiyon olsun. Herhangi sonlu X üzerinde oluşturulan çekirdek matrisi pozitif yarıtanımlı ise yani negatif özdeğeri yoksa k bir Mercer çekirdeğidir.

Farklı kaynaklardan elde edilen özniteliklerin farklı Hilbert uzaylarına aktarılması ve bu bilgilerin birarada kullanılması ihtiyacı BÇ ailesini ortaya çıkarmıştır. Örnek bir uygulama çalışması olarak bir BÇ ailesi ile hiperspektral görüntülerde spektral ve uzamsal bilginin sınıflandırma amaçlı birleştirilmesi verilebilir [22]. Hiperspektral görüntülerde çekirdek yöntemlerle sınıflandırma genellikle spektral özelliklerin kullanılması ile gerçekleştirilmekte ve tatmin edici sonuçlar üretilmektedir. Bunun yanında, uzamsal özelliklerin (örn. dokusal) kullanıldığı yöntemlerle (k -en yakın komşuluk, yapay sinir ağları) de başarılı sonuçlar üretilmiştir. Camps-Valls vd. [22] yaptıkları çalışmada çekirdek ailesinin özelliklerini kullanarak spektral, uzamsal ve bu ikisinin çapraz bilgisinin kullanıldığı bir çekirdek ailesi oluşturmuşlar ve sınıflandırma başarısını tekli kullanım durumlarına göre artırmışlardır.

BÇ kavramı her ne kadar her türlü veri ve uygun tanımlanmış çekirdek için geçerli olsa da, bu kısımda, teorik altyapısı yukarıda verilen örnek üzerinden anlatılacaktır. Belirtildiği gibi, hiperspektral görüntü sınıflandırmada genel eğilim verinin spektral içeriğinin ($\mathbf{x}_i \equiv \mathbf{x}_i^s$) kullanılmasıdır. Bununla birlikte, sınıflandırma performansı spektral ve uzamsal bilginin (\mathbf{x}_i^u) dâhil edilmesiyle artırılabilir. Bu birliktelik, normal olarak spektral ve uzamsal özniteliklerin “yığılı” bir yaklaşımla birbirine bağlanmasıyla yapılır. Bir ϕ eşleme fonksiyonu, böyle bir birlikteliği ($\mathbf{x}_i \equiv \{\mathbf{x}_i^s, \mathbf{x}_i^u\}$) dönüştürmek için kullanılırsa, karşılık gelen yığılı çekirdek fonksiyonu çıkışı elde edilir [22].

$$k_{\{s,u\}} \equiv k(\mathbf{x}_i, \mathbf{x}_j) = \langle \phi(\mathbf{x}_i), \phi(\mathbf{x}_j) \rangle \quad (3.22)$$

Bu ifade, elbette, spektral ve uzamsal özniteliklerin çapraz ilişkisi hakkında bir bilgi içermemektedir.

3.2.2.1 Çekirdeklerin Doğrudan Toplamı

Spektral ve uzamsal bilginin birleştirilmesini sağlayan basit bir bileşik çekirdek \mathbf{x}_i^s ve \mathbf{x}_i^u öznitelik vektörlerinin doğrusal olmayan dönüşümlerinden doğal olarak gelmektedir. İki farklı Hilbert uzayına dönüşüm sağlayan ϕ_1 ve ϕ_2 eşleme kurallarını ele alalım. Eşitlik 3.23 ile verilen dönüşüm oluşturulur.

$$\phi(\mathbf{x}_i) = \{\phi_1(\mathbf{x}_i^s), \phi_2(\mathbf{x}_i^u)\} \quad (3.23)$$

Karşılık gelen iç çarpım:

$$\begin{aligned} k(\mathbf{x}_i, \mathbf{x}_j) &= \langle \phi(\mathbf{x}_i), \phi(\mathbf{x}_j) \rangle \\ &= \langle \{\phi_1(\mathbf{x}_i^s), \phi_2(\mathbf{x}_i^u)\}, \{\phi_1(\mathbf{x}_j^s), \phi_2(\mathbf{x}_j^u)\} \rangle \\ &= k_s(\mathbf{x}_i^s, \mathbf{x}_j^s) + k_u(\mathbf{x}_i^u, \mathbf{x}_j^u) \end{aligned} \quad (3.24)$$

Burada sonucun, spektral ve uzamsal kaynaklı bilginin pozitif tanımlı matrislerini oluşturan değerlerin toplamı olduğuna dikkat edilmelidir. Başka bir deyişle, nihai çekirdek matrisi ayrı ayrı çekirdek matrislerinin toplamıyla elde edilebilir. Eşitlik 3.24 ile verilen durum, iki çekirdek fonksiyonu toplamının tek bir çekirdek fonksiyonu ile ulaşılabilir olduğuna yani bu toplamın ayrı bir geçerli fonksiyon çıkışına denk olduğuna işaret etmektedir. Bu çıkarıma dayanak, çekirdek tabanlı öğrenme yaklaşımının temelini oluşturan ve bu nedenle Mercer'in çekirdekleri olarak adlandırılan fonksiyonların özelliklerinde bulunabilir [53].

Mercer çekirdeklerinin özellikleri. Geçerli Mercer çekirdekleri k_1 ve k_2 ile $\alpha > 0$ gerçel sayısı verilsin. Bu halde, verilen fonksiyonlar geçerli çekirdeklerdir: 1) $k(\mathbf{x}_i, \mathbf{x}_j) = k_1(\mathbf{x}_i, \mathbf{x}_j) + k_2(\mathbf{x}_i, \mathbf{x}_j)$; 2) $k(\mathbf{x}_i, \mathbf{x}_j) = \alpha k_1(\mathbf{x}_i, \mathbf{x}_j)$.

3.2.2.2 Çekirdeklerin Ağırlıklı Toplamı

Çekirdek ailesinin özellikleri kullanılarak uzamsal ve spektral içerik arasındaki dengeyi ayarlayan bir bileşik çekirdek oluşturulabilir.

$$k(\mathbf{x}_i, \mathbf{x}_j) = \mu k_s(\mathbf{x}_i^s, \mathbf{x}_j^s) + (1 - \mu) k_u(\mathbf{x}_i^u, \mathbf{x}_j^u) \quad (3.25)$$

Burada μ , $0 < \mu < 1$ aralığında pozitif bir bağımsız parametredir ve verilen bir sınıflandırma probleminde farklı bilgi kaynakları arasındaki ödünleşimi ayarlar.

3.2.2.3 Çapraz-bilgi Taşıyan Çekirdek

Çekirdek sınıflandırıcılar birden fazla kaynaklı özniteliklerin çapraz bilgisinin çıkarılması amacıyla da kullanılabilir. Uzamsal ve spektral bilginin çapraz ilişkisinin hesaba katıldığı ve $\phi(\cdot)$ fonksiyonunun doğrusal olmayan eşleme olarak kullanıldığı durumu düşünelim. O halde, Eşitlik 3.26 ile verilen bir bileşik vektör oluşturulabilir.

$$\phi(\mathbf{x}_i) = \{\phi(\mathbf{x}_i^s), \phi(\mathbf{x}_i^u), \phi(\mathbf{x}_i^s) + \phi(\mathbf{x}_i^u)\} \quad (3.26)$$

İç çarpım hesaplanırsa:

$$\begin{aligned} k(\mathbf{x}_i, \mathbf{x}_j) &= \langle \phi(\mathbf{x}_i), \phi(\mathbf{x}_j) \rangle \\ &= \phi(\mathbf{x}_i^s)^\top \phi(\mathbf{x}_j^s) + \phi(\mathbf{x}_i^u)^\top \phi(\mathbf{x}_j^u) \\ &\quad + \phi(\mathbf{x}_i^s)^\top \phi(\mathbf{x}_j^u) + \phi(\mathbf{x}_i^u)^\top \phi(\mathbf{x}_j^s) \end{aligned} \quad (3.27)$$

Doğrudan toplam durumunda olduğu gibi burada da, Eşitlik 3.27 ile verilen iç çarpım sonucu çekirdek matrislerinin toplamı olarak ifade edilebilir.

$$k(\mathbf{x}_i, \mathbf{x}_j) = k_s(\mathbf{x}_i^s, \mathbf{x}_j^s) + k_u(\mathbf{x}_i^u, \mathbf{x}_j^u) + k_{su}(\mathbf{x}_i^s, \mathbf{x}_j^u) + k_{us}(\mathbf{x}_i^u, \mathbf{x}_j^s) \quad (3.28)$$

Bu matrisler sırasıyla spektral bilgiyi, uzamsal bilgiyi ve bu iki bilginin çapraz ilişkilerini taşımaktadır. Burada tek kısıt, \mathbf{x}_i^s ve \mathbf{x}_j^u öznitelik vektörlerinin önceki durumların aksine aynı boyutta olmaları gerekliliğidir.

3.2.3 Çoklu-çekirdek Öğrenmesi (ÇÇÖ)

Daha önce de belirtildiği gibi (Bkz. Bölüm 3.2.1), çekirdek ve parametrelerinin seçimi üzerine yapılan çalışmalar göstermiştir ki hiçbir çekirdek pratikte en iyi değildir. Tek bir çekirdek kullanmak yerine farklı çekirdeklerin veri üzerindeki farklı karakteristikleri aynı anda çıkarmalarını sağlamak için, araştırmacılar çekirdek birleşimi yöntemlerine yönelmiştir. Bunlardan en klasik ve ilkel olanı çekirdek çıktılarının ortalamasını almaktır. Bu durumda çekirdek ağırlıkları eşit olacaktır. Ayrıca, çeşitli optimizasyon yöntemleri ve sezgisel yaklaşımlar çekirdek ağırlıklarını belirlemek amacıyla literatürde önerilmiştir [15]-[19]. Bu çalışmalar, beklenildiği gibi, DVM sınıflandırıcısı özelinde yoğunlaşmıştır.

Tez kapsamında, çoklu-çekirdek öğrenmesi (ÇÇÖ) kavramına, daha az çalışıldığı tarafıyla topluluk öğrenme (TÖ) stratejisi üzerinden yaklaşılmıştır. TÖ yöntemleri istatistiksel bir yaklaşım olup daha kararlı ve gürbüz bir öğrenme algoritması oluşturmak için alt yöntemlerin gürbüz olmayan kararlarının birleştirilmesini amaçlar. Bu tanımdan anlaşılacağı üzere, bu yaklaşımda tek bir sınıflandırıcı yerine birden çok sınıflandırıcıyı içerecek şekilde bir sınıflandırıcı kümesinin oluşturulması ve elde edilen sonuçların uygun bir şekilde birleştirilmesi ile daha yüksek doğruluk ve kararlılığa ulaşılması hedeflenmektedir. Bir TÖ algoritmasında her bir alt/zayıf sınıflandırıcı, aynı sınıflandırma algoritmasının farklı çekirdek ve/veya çekirdek parametreleri ile oluşturulmuş halleri olarak alındığında, bu sınıflandırıcıların kararlarının birleştirilmesi aynı zamanda ÇÇÖ probleminin çözümü olacaktır. Buradan hareketle söylenebilir ki ÇÇÖ ailesi TÖ yöntemlerinin özel bir durumudur [23]. TÖ yöntemlerinde de alt sınıflandırıcıların birleşimlerinin elde edilmesi için çeşitli yaklaşımlar vardır. Bunlar ağırlıklı ve ağırlıksız yaklaşımlar olarak ikiye ayrılabilirdiği gibi, ağırlıklı yaklaşımlar üzerinde doğal olarak pek çok çalışma mevcuttur. İlerleyen bölümde ÇÇÖ ile TÖ arasındaki ilişki ortaya konulmuştur.

3.2.3.1 Çoklu-çekirdek Öğrenmesi ve Topluluk Öğrenme İlişkisi

ÇÇÖ’de birçok alt çekirdek mevcuttur. Her bir çekirdek veriyi karşılık gelen Çoğaltma Çekirdek Hilbert Uzayı’na (ÇÇHU) eşler. ÇÇÖ bu çekirdekleri birleştirir ve tek bir çekirdek oluşturur. Bu birleşmiş çekirdek veriyi farklı bir ÇÇHU’ya taşır ve bu uzayda ÇÇÖ örnekler arasındaki en büyük ayırma yüzeyini bulmaya çalışır. Bu kısımda, ÇÇÖ ile TÖ arasındaki bağlantı DVM üzerinden anlatılmıştır.

N adet iki-sınıflı (\mathbf{x}_i, y_i) örnekleri verilsin, $y_i = \{\pm 1\}$. Eşleme fonksiyonu f_m , yanlılık terimi b , yapay değişken ζ_i ve C ceza katsayısı olsun. d_m yeni birleşik çekirdek oluşumu için kullanılacak her bir alt-çekirdek ağırlığı olmak üzere; $\langle g, h \rangle_{H_m} = 1/d_m \langle g, h \rangle_{H_m}$. ÇÇÖ Eşitlik 3.29 ile formüle edilir [54]:

$$G = \min_{f, b, \zeta} \frac{1}{2} \sum_m \frac{1}{d_m} \|f_m\|_{H_m}^2 + C \sum_i \zeta_i \quad (3.29)$$

Bu ifadenin kısıtları:

$$y_i (\sum_m f_m(\mathbf{x}_i) + b) \geq 1 - \zeta_i \quad \forall i \quad (3.30)$$

$$\zeta_i \geq 0 \quad \forall i$$

$$\sum_m d_m = 1, \quad d_m \geq 0 \quad \forall m$$

Çekirdekler Eşitlik 3.29'a dâhil edilirse:

$$G = \min_{d_m} \max_{\alpha} \sum_i \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j \sum_m d_m k_m(\mathbf{x}_i, \mathbf{x}_j) \quad (3.31)$$

elde edilir. Bu ifadenin kısıtları:

$$\sum_i \alpha_i y_i = 0 \quad (3.32)$$

$$C \geq \alpha_i \geq 0 \quad \forall i$$

$$\sum_m d_m = 1, \quad d_m \geq 0 \quad \forall m$$

Eşitlik 3.32'de α destek vektör katsayısı, k_m alt-çekirdek ve d_m her bir alt-çekirdeğin ağırlığıdır. Alt-çekirdeklerin ağırlıklı toplamı olarak yeni bir çekirdek $k_{yeni} = \sum_m d_m k_m$ olsun. Her k_m pozitif tanımlı olmak üzere, Eşitlik 3.32 ile verilen bir konveks optimizasyon problemidir. Çözülmesi gereken iki parametre bulunmaktadır. Uygun çözümlere $\{\alpha^*, d_m^*\}$ ulaşıldığını varsayarsak yeni eşitlik:

$$G = \sum_i \alpha_i^* - \frac{1}{2} \sum_{i,j} \alpha_i^* \alpha_j^* y_i y_j \sum_m d_m^* k_m(\mathbf{x}_i, \mathbf{x}_j) \quad (3.33)$$

ile verilir. Bu ifadenin kısıtları ise:

$$\sum_i \alpha_i^* y_i = 0 \quad (3.34)$$

$$C \geq \alpha_i^* \geq 0 \quad \forall i$$

$$\sum_m d_m^* = 1, \quad d_m^* \geq 0 \quad \forall m$$

Alt-çekirdek katsayıları toplamı $\sum_m d_m^* = 1$ olduğundan, Eşitlik 3.33 yerine

$$G = \sum_m d_m^* \left[\sum_i \alpha_i^* - \frac{1}{2} \sum_{i,j} \alpha_i^* \alpha_j^* y_i y_j k_m(\mathbf{x}_i, \mathbf{x}_j) \right] \quad (3.35)$$

yazılır. Bu ifadenin kısıtları Eşitlik 3.34'de verildiği gibidir. Eşitlik 3.35'deki köşeli parantezli olan kısım alınırsa:

$$g_m = \sum_i \alpha_i^* - \frac{1}{2} \sum_{i,j} \alpha_i^* \alpha_j^* y_i y_j k_m(\mathbf{x}_i, \mathbf{x}_j) \quad (3.36)$$

elde edilir. Bu kısım için kısıtlar ise:

$$\sum_i \alpha_i^* y_i = 0 \quad (3.37)$$

$$C \geq \alpha_i^* \geq 0 \quad \forall i$$

Eşitlik 3.36 esasında bir çekirdek DVM sınıflandırıcıdır, ancak α^* alt-çekirdek k_m için değil, yeni birleşik çekirdek k_{yeni} için sınıflandırıcının uygun çözümüdür. k_m burada uygun olmayan ya da zayıf sınıflandırıcı olarak isimlendirilir. Buradan hareketle, Eşitlik 3.35 ile verilen ifade ve kısıtı:

$$G = \sum_m d_m^* g_m \quad (3.38)$$

$$\sum_m d_m^* = 1, \quad d_m^* \geq 0 \quad \forall m$$

şeklinde yazılabilir. Eşitlik 3.38'den anlaşılacağı üzere ÇÇÖ, çoklu zayıf sınıflandırıcıların uygun doğrusal birleşimlerinin çözülmesi süreci olarak kabul edilebilir.

Test sürecinde karar kuralı:

$$\begin{aligned} y &= \text{sign}[\sum_m d_m^* \alpha^* k_{m,\alpha^*}(\mathbf{x}_{\alpha^*}, \mathbf{x}_{test}) + b] \\ &= \text{sign}\{\sum_m d_m^* [\alpha^* k_{m,\alpha^*}(\mathbf{x}_{\alpha^*}, \mathbf{x}_{test}) + b]\} \\ &= \text{sign}[\sum_m d_m^* tah_m] \end{aligned} \quad (3.39)$$

Bu kurala ait kısıt:

$$\sum_m d_m^* = 1, \quad d_m^* \geq 0 \quad \forall m \quad (3.40)$$

Eşitlik 3.39'da, k_{m,α^*} destek vektörler ve test kümesi ile oluşturulmuş alt-çekirdek matrisini temsil eder. $tah_m = \alpha^* k_{m,\alpha^*}(\mathbf{x}_{\alpha^*}, \mathbf{x}_{test}) + b$ kısmı ise her bir sınıflandırıcının tahminini göstermektedir. Sonuç, çoklu alt-sınıflandırıcıların tahminlerinin ağırlıklı toplamıdır. Daha önce belirtildiği gibi, TÖ de çoklu sınıflandırıcıların nasıl bir araya getirilebileceğini araştırmaktadır. ÇÇÖ probleminde alt-çekirdeklerin aynı boyutta olmaları ve aynı sayıda destek vektör tutmaları gibi kısıtlar bulunmaktadır. TÖ yaklaşımında ise bu durumlardan etkilenilmez. Buradan, ÇÇÖ yaklaşımının TÖ yöntemlerinin bir özel hali olduğu sonucu çıkarılabilir [23].

TÖ yeniden örneklenen eğitim kümeleri üzerinde sınıflandırıcıların eğitilmesi veya farklı sınıflandırıcıların aynı eğitim kümesi üzerinde ayrı ayrı eğitilmesi ve sonuçta ortaya çıkan tahminlerin birleştirilmesi ile gerçekleştirilebilir. Literatürde TÖ algoritmaları kullanımı ile sınıflandırma performansında önemli derecede artış olduğu vurgulanmaktadır.

Günümüze kadar TÖ algoritması olarak başta torbalama ve rasgele orman olmak üzere birçok yaklaşım geliştirilmiştir. Literatürde uygulanan algoritmaları 3 ana yapıda inceleyebiliriz;

- **Veri seviyesi birleştirme:** Burada eldeki örnek küme veri kümesinden tekrar örneklemeyle elde edilen veri kümeleri ile aynı sınıflandırıcılar eğitilerek sonuçlar birleştirilmektedir. Torbalama (*Bagging*) ve hızlandırma (*boosting*) bu tip TÖ algoritmalarıdır.
- **Öznitelik seviyesi birleştirme:** Orijinal öznitelik vektöründen, farklı alt seviye öznitelikler genellikle tek bir yöntemle sınıflandırılarak sonuçlar birleştirilmektedir.
- **Sınıflandırıcı seviyesi birleştirme:** Aynı örnek veri kümesi üzerinde, farklı sınıflandırıcıların eğitilmesiyle elde edilen sonuçların birleştirilmesidir.

TÖ algoritmalarında her bir sınıflandırıcının paralel veya seri işletilmesi yapılabilmektedir. Paralel yöntemlerde; her bir sınıflandırıcıdan (temel sınıflandırıcı) sonuçlar alınır ve ardından uygun birleştirme yöntemleri kullanılarak nihai sonuç elde edilir. Seri yöntemlerde ise, her bir sınıflandırma işlemi ardışık uygulanarak bir sonraki sınıflandırıcının bir öncekinin doğru ve/veya yanlış tahminlerine dayalı bir sonuç çıkarması beklenmektedir. Literatürde en yaygın kullanılan TÖ algoritmaları, Torbalama (*Bagging*), Hızlandırma (*Boosting*), Rasgele Altuzay (*Random SubSpace*) yöntemleridir. Bu yöntemlerden hangisi seçilirse seçilsin TÖ yöntemlerinde en önemli hususlardan birisi de elde edilen tahminlerin daha iyi sonuç verecek şekilde birleştirilmesidir.

Veri birleştirmede doğrusal ve doğrusal olmayan yöntemler kullanılmaktadır. Doğrusal yöntemlerden en basit ve yaygın kullanılanı ağırlıksız çoğunluk oylamasıdır. Bu yöntemde her bir test örneği için en çok hangi etiketleme yapılmışsa o etikete atanmış sınıf seçilir. Ancak bu yöntemde her zaman en iyi sonuç elde edilememektedir. Bu nedenle daha gülbüz sonuçların elde edilebilmesi için ağırlıklı oylama yöntemleri kullanılmaktadır. Bu yöntemde her bir sınıflayıcı sonucuna bir ağırlık verilerek oylama yapılır. Eğer ağırlık uygun bir şekilde verilebilirse birleştirme sonucu daha iyi çıkabilmektedir. Bu nedenle, TÖ yöntemlerinde birleştirme öncesi sonuçlara uygun ağırlıklar verme önemli bir aşamadır. Nihai karar fonksiyonu ağırlıksız oylama için:

$$f = \underset{j}{\operatorname{argmax}} (C_j) \quad (3.41)$$


Ağırlıklı oylama için:

$$f = \underset{j}{\operatorname{argmax}} (w_i \times C_j) \quad (3.42)$$

Eşitlik 3.41 ve 3.42’de $j \in \{\pm 1\}$ olmak üzere iki-sınıflı sınıf etiketlerini, C_j ise j ’inci sınıfa ait olanların sayısını göstermektedir.

3.3 Çekirdek Fukunaga-Koontz Dönüşümü için Çekirdek Parametresi Seçimi

Çekirdek parametresi olarak uygun değerlerin seçilmesi çekirdek-tabanlı öğrenme algoritmalarının diğer bir önemli problemidir. Parametre seçiminde ilk yaklaşımlar, deneye bağlı en iyi performansı gösteren değerlerin seçilmesi ya da çapraz-doğrulama (*cross-validation*) yaklaşımının kullanılmasına dayanmaktadır [11]. Bununla birlikte, bu yaklaşımlar zaman tüketimi açısından kullanışlı gözükmemektedir. Pozitif ve negatif sınıf örneklerini öznetelik uzayında oldukça uzak bölgelere eşleyen RTF parametresinin bir optimizasyon problemine bağlı olarak belirlenmesi için $\sigma \in \mathbb{R}^+$ değerlerine karşılık ÇFKD algoritmasının ürettiği geri getirme oranı (GGO) (*recall*) incelenmiştir.



Şekil 3.2 Farklı σ değerleri ile geri getirme oranının değişimi (üst) *Corn-no till* (alt) *Grass / pasture*

Ayrıntıları deneysel sonuçlar bölümünde verilecek olan AVIRIS *Indian Pine* hiperspektral veri kümesine ait iki sınıf (*Corn-no till* ve *Grass / pasture*) hedef sınıflar olarak kabul edilerek, bu iki hedef için iki ayrı test gerçekleştirilmiştir. Söz konusu test, bir sınıfın hedef olduğu durum için gerçekleştirilirken, diğer sınıf ve görüntünün geri kalanı (arka plan) hedef-olmayan sınıf olarak kabul edilmektedir. Çekirdek fonksiyonu olarak RTF kullanılmış ve ilk önce farklı σ değerleri ile bu değerlerin GGO (yani her bir σ değeri için yöntemin hedefin ne kadarını doğru tespit edebildiğinin oranı) hesaplanmıştır. Şekil 3.2 AVIRIS *Indian Pine* hiperspektral veri kümesine ait iki sınıf için test sonuçlarını göstermektedir.

Kolayca farkedilebilir ki maksimum geri getirme oranlarına karşılık gelen σ , *corn-no till* için [0.12-0.14], *grass/pasture* için [0.10-0.13] aralığındadır. Bu aralıklarda ÇFKD adımları incelendiğinde hedef ve hedef-olmayan çekirdek matrisi değerlerinin birbirinden oldukça uzak olduğu görülmüştür. Başka bir ifadeyle, bu iki matrisin her noktada değerlerinin oranı büyüdükçe ÇFKD'nin hedefi ayırt etme yeteneği artmaktadır. Hedef sınıfı (\mathbf{X}) için \mathbf{x}_i ve \mathbf{x}_j eğitim örnekleri olmak üzere, $\forall i, j = 1, \dots, M$, Eşitlik 3.43 hedef sınıfta eğitim örneklerinin RTF çekirdek fonksiyonundan çıkan değerlerinin toplamını hesaplamaktadır.

$$x(\sigma) = \sum_{i,j=1}^M \sum_{\mathbf{x}_i \in \mathbf{X}} \sum_{\mathbf{x}_j \in \mathbf{X}} k_{RTF}(\mathbf{x}_i, \mathbf{x}_j, \sigma) \quad (3.43)$$

Sonraki adımda, \mathbf{y}_i ve \mathbf{y}_j arka plan (\mathbf{Y}) karışıklığında eğitim örnekleri olmak üzere, $\forall i, j = 1, \dots, M$, söz edilen sınıfta eğitim örneklerinin RTF çekirdek fonksiyonundan çıkan değerlerinin toplamı Eşitlik 3.44 ile verilir.


$$y(\sigma) = \sum_{i,j=1}^M \sum_{\mathbf{y}_i \in \mathbf{Y}} \sum_{\mathbf{y}_j \in \mathbf{Y}} k_{RTF}(\mathbf{y}_i, \mathbf{y}_j, \sigma) \quad (3.44)$$

Uygun çekirdek parametresini kestirmek için aşağıdaki optimizasyon problemi geliştirilmiştir.

$$\min_{\sigma > 0} J(\sigma) := \frac{y(\sigma)}{x(\sigma)} \quad (3.45)$$

Yukarıdaki adımlarda, uygun σ (sigma) değeri olduğu düşünülen herhangi bir aralıkta arama yapılabilmektedir. Bu adımlar sayesinde hedef ve hedef-olmayan eğitim örneklerini öznitelik uzayında oldukça uzak bölgelere eşleyen parametreler seçilebilmektedir.

Yukarıda sözü geçen eşitliklerle $J(\sigma)$ fonksiyonu hesaplanmış ve sigma değerlerine karşılık $J(\sigma)$ değerleri kullanılarak aşağıda verilen grafikler oluşturulmuştur (Şekil 3.3). Bu grafikte çizilmiş olan $J(\sigma)$ fonksiyonunun çukur bölgeleri göstermiştir ki oluşturulan bu optimizasyon kriteri, uygun çekirdek parametresi değerini doğru bir şekilde kestirmektedir. Çünkü burada uygulanan optimizasyon kuralı, $J(\sigma)$ fonksiyonunun minimum değerinde olmasını gerektirmektedir. Şekil 3.3’de bu minimum değere karşılık gelen sigmanın *corn-no till* için [0.12-0.14] aralığında, *grass/pasture* için de [0.10-0.13] aralığında olduğu görülmektedir.



Şekil 3.3 *Corn-no till* (sol) ve *Grass / pasture* (sağ) için σ değerlerine karşılık $J(\sigma)$ değişimi (y-ekseni logaritmik ölçekle çizilmiştir)

Yukarıda bahsi geçen Eşitlik 3.45, benzerlik gösteren yani aynı sınıfa giren örnekler için, farklı sınıflara giren örnekler için ürettiklerinden daha yüksek skor üreten çekirdek tiplerine uygulanabilmektedir. Benzerlik göstermeyen yani farklı sınıflara giren örnekler için daha yüksek skor üreten çekirdek tiplerine ise Eşitlik 3.45 yerine aşağıdaki eşitlik uygulanarak işlemler sürdürülebilir.

$$\max_{\sigma > 0} J(\sigma) := y(\sigma) / x(\sigma) \quad (3.46)$$

Yukarıda Eşitlik 3.43’den Eşitlik 3.45’e kadar olan adımlarla geliştirilen optimizasyon problemi literatürdeki herhangi bir optimizasyon yaklaşımı ile çözülebilecek yapıdadır. Ayrıca, yukarıda formülleştirilen yöntem adımları tek bir bağımsız parametresi olan çekirdek fonksiyonları için uygulanabilecek niteliktedir. Tez kapsamında, söz konusu optimizasyon probleminin çözümü için diferansiyel gelişim algoritması (DGA) [14] tercih edilmiştir. Bu tercihin nedeni, söz konusu yöntemin hafıza gereksinimleri ve işlem

süreleri bakımından maliyetli olmamasıdır. DGA, sürekli bir uzayda enküçültme optimizasyon problemini çözmek için önerilmiştir.

$$\min f(X_1, \dots, X_j, \dots, X_D) \quad (3.47)$$

Bu ifadenin kısıtı:

$$X_j^L \leq X_j \leq X_j^U, \quad j = 1, 2, \dots, D \quad (3.48)$$

Burada, D problemin boyutunu, X_j^L ve X_j^U ise sırasıyla X_j vektörünün j . elemanının en düşük ve en yüksek değerlerini göstermektedir. DGA bir kayan noktalı kodlama şeması kullanır. Ardışık popülasyonlar, rasgele seçilen iki vektörün ağırlıklandırılmış farkının yine rasgele seçilen üçüncü bir vektöre algoritma operatörleri olan mutasyon, çaprazlama ve seçme yardımıyla eklenmesiyle elde edilir. DGA işleyiş süreci aşağıda verilen dört adımla özetlenmiştir.


- **Başlatma:** Başlangıç popülasyonu X rasgele üretilir. Popülasyon büyüklüğü literatürde NP ile gösterilmiştir.
- **Mutasyon:** Algoritma, rasgele belirlenmiş vektör farklarının bir F ölçeklendirme faktörü ile beraber üçüncü bir vektöre eklenmesiyle mutasyona uğramış vektörleri (V_i^t) üreterek yeniden oluşturur.
- **Çaprazlama:** Deneme vektörü U_i^t , hedef vektörün X_i^t mutasyona uğramış vektör V_i^t ile çaprazlama olasılığı (CR) kadar karıştırılmasıyla oluşturulur.
- **Seçme:** DGA, popülasyon vektörü X_i^t ve onun karşılığı olan deneme vektörünün (U_i^t) hedef fonksiyonu çıkışlarını inceler. En küçük değeri üreten üye yeni nesle aktarılacaktır.

DGA görüleceği üzere genetik algoritma (GA) ile benzerlik göstermektedir. Literatürde DGA yaklaşımının özellikle hız açısından GA yöntemine üstün olduğu vurgulanmıştır [14].


3.4 Deneysel Sonuçlar

Bu bölümde FGD, ÇFGD, KÇB, BÇ, TÖ ile ÇÇÖ ve ÇFGD için çekirdek parametre seçimi deneyleri sonuçlarına yer verilmiştir.

FKD ve ÇFKD ile Hiperspektral Görüntülerde Sınıflandırma: Bu kısımda, hiperspektral görüntüler üzerinde ÇFKD tabanlı bir eğitici çok-sınıflı sınıflandırma uygulaması üzerinde durulmuştur. Gerçek-dünya hiperspektral uygulamalarında eğitim örneklerinin toplanması genel olarak zorlu ve pahalı bir işlemdir. Erişime açık veri kümelerinde de bu nedenle eğitim örneklerinin hacmi kısıtlı olmaktadır. Oysa gürbüz ve doğru bir sınıflandırıcı modelinin oluşturulabilmesi için yeterli miktarda yer-doğruluğu olan örneğe ihtiyaç duyulmaktadır [55], [56]. Bu durum hiperspektral görüntü işleme alanında önemli bir çalışma alanını oluşturmakta ve Hughes fenomeni olarak bilinmektedir [44]. Bu fenomen, eğitim örnekleri sayısının öznelik sayısından görece az olduğu durumlarda aşırı öğrenme ve düşük genelleştirme yeteneğinin ortaya çıkacağını vurgulamaktadır. Buradan hareketle, bu kısımda, görece düşük sayıda eğitim örnekleri ile gerçekleştirilen bir sınıflandırma uygulaması konu edilmiştir. Bunun yanında, ÇFKD algoritmasının daha önce literatürde kullanmadığı Laplace tipi, Cauchy ve logaritmik çekirdekler de uygulanmış ve karşılaştırmalı sonuçlara yer verilmiştir.



Şekil 3.4 *Indian Pine* hiperspektral verisinin bir kısmı: (sol) Sahte renkli görüntü {R:100, G:150, B:25} (sağ) 16 sınıflı doğrulama verisi



Şekil 3.5 *DC Mall* hiperspektral verisinin bir kısmı: (üst) Sahte renkli görüntü {R:90, G:120, B:40} (alt) 7 sınıflı doğrulama verisi

Deneylerde iki gerçek hiperspektral veri kullanılmıştır. İlki AVIRIS (*Airborne Visible/Infrared Imaging Spectrometer*) hava platformu sensörleri ile 1992 Haziran ayında alınmış Indiana (ABD) eyaleti kuzeybatı bölgesinin bir bölümünü içeren görüntüdür [57]. *Indian Pine* veri kümesi 145×145 uzamsal boyutlarda 16 tarım ürünü sınıfı içermektedir. Orijinalinde 220 spektral banda (0.4-2.5 μm aralığında 10-nm spektral çözünürlük) sahip olan veri, gürültülü ve su buharı etkisindeki bantların elenmesiyle kalan 200 bant üzerinden deneylerde kullanılmıştır. *Indian Pine* verisi orijinalinde 16 sınıflı olmakla birlikte, örnek sayısı görece yüksek olan sınıfların alındığı 9 sınıflı versiyonu da literatürde kullanılmaktadır. Bu çalışmada, küçük örnek boyutlu sınıflandırma üzerinde durulduğundan hem 9 hem de 16 sınıflı versiyon deneylerde tercih edilmiştir. Verinin üç kanallı birleşik bir görüntüsü ve karşılık gelen yer-doğruluğu Şekil 3.4’de verilmiştir.

Çizelge 3.1 *Indian Pine* ve *DC Mall* verilerine ait sınıf bilgisi

AVIRIS Indian Pine		HYDICE DC Mall			
	Sınıf	Örnek Sayısı	Sınıf	Örnek Sayısı	
16 SINIF	9 SINIF	Corn-no till	1434	Roof	3834
		Corn-min till	834	Street	416
		Grass-pasture	497	Path	175
		Grass-trees	747	Grass	1928
		Hay-widrowed	489	Trees	405
		Soybean-no till	968	Water	1224
		Soybean-min till	2468	Shadow	97
		Soybean-clean till	614	Toplam	8079
		Woods	1294		
	Toplam (9 sınıf)		9345		
		Alfalfa	54		
		Corn	234		
		Grass-past.mowed	26		
		Oats	20		
		Wheat	212		
		Bldg-Grass-Tree-Drives	380		
	Stone-Steeltowers	95			
Toplam (16 sınıf)		10366			

İkinci hiperspektral veri Washington, DC Mall üzerinden HYDICE (*HYperspectral Digital Imagery Collection Experiment*) algılayıcıları ile alınmış veridir [58]. *DC Mall* verisi 1208×307 uzamsal boyutlarda 7 sınıflı bir sahnedir. Verinin üç kanallı birleşik bir görüntüsü ve karşılık gelen yer-doğruluğu Şekil 3.5’de sunulmuştur. Veri, gürültülü ve

su buharı etkisindeki bantların elenmesiyle 220 banttan geriye kalan 191 bant üzerinden deneylerde kullanılmıştır. *Indian Pine* ve *DC Mall* verilerine ait özet bilgi Çizelge 3.1’de verilmiştir. Deneylerde FKD ve ÇFKD kullanılarak, hiperspektral görüntülerde küçük örnek boyutlu sınıflandırma performansı karşılaştırmalı olarak araştırılmıştır. Bu amaçla, 5, 10 ve 15 eğitim örneğinin seçildiği 16 sınıflı *Indian Pine* verisi ile ve her sınıftan 5, 10, 15, 20, 30, 50 örnek seçilerek 9 sınıflı *Indian Pine* verisi ve *DC Mall* verileri ile toplamda 3 bağımsız deney gerçekleştirilmiştir.

Çizelge 3.2 Kullanılan çekirdekler

Çekirdek	Formül
RTF	$K_{RTF}(\mathbf{x}, \mathbf{y}) = \exp(-\ \mathbf{x} - \mathbf{y}\ ^2 / 2\sigma^2)$
Laplace	$K_{Laplace}(\mathbf{x}, \mathbf{y}) = \exp(-\ \mathbf{x} - \mathbf{y}\ / \sigma)$
Cauchy	$K_{Cauchy}(\mathbf{x}, \mathbf{y}) = 1 / (1 + \ \mathbf{x} - \mathbf{y}\ ^2 / \sigma)$
Logaritmik	$K_{log}(\mathbf{x}, \mathbf{y}) = -\log(\ \mathbf{x} - \mathbf{y}\ ^d + 1)$

Eğitim örnekleri rasgele seçilmiş ve geriye kalan örnekler bire-karşı-hepsi stratejisinin uygulandığı çok-sınıflı sınıflandırma sürecinde değerlendirilmiştir. ÇFKD oluşturulması aşamasında dört adet çekirdek (Çizelge 3.2) birbirinden bağımsız olarak denenmiş ve performansları FKD ile birlikte verilmiştir.

Çekirdek parametreleri belirli bir aralıktaki aday değerlerden deneysel olarak iyi olanının seçilmesiyle belirlenmiştir. Sınıflandırma sonuçları literatürde sıklıkla kullanılan destek vektör makineleri (DVM) ile de karşılaştırılmış ve bu amaçla doğrusal olmayan DVM sınıflandırıcıyı modellemek için RTF çekirdek uygulanmıştır. DVM parametreleri 10-katlı çapraz-doğrulama kullanılarak belirlenmiştir.

Farklı sayıda eğitim örneklerine karşılık orijinal özniteliklerle, temel bileşen analizi (TBA) ve çekirdek temel bileşen analizi (ÇTBA) ile çıkarılan özniteliklerle üretilen DVM genel sınıflandırma doğrulukları Çizelge 3.3’de verilmiştir. TBA ve ÇTBA ile öznitelik çıkarımında en yüksek özdeğerlerin %40’ı korunmuştur.

Tez kapsamında önerilen ve bu kısımda anlatılan çok-sınıflı FKD ve ÇFKD yöntemleri ile 9 sınıflı sonucu *Indian Pine* verisi için sınıflandırma performansı Çizelge 3.4’de sunulmuştur.

Çizelge 3.3 Orijinal, TBA ve ÇTBA öznitelikleri kullanılarak farklı sayıda eğitim örnekleri ile üretilen DVM genel sınıflandırma doğruluğu (%)

Eğitim Örnekleri Sayısı						
Orijinal Öznitelikler	5	10	15	20	30	50
Indian Pine (9 sınıf)	54.87	59.81	64.04	67.59	71.87	77.23
Indian Pine (16 sınıf)	46.06	54.63	60.02	—	—	—
DC Mall	84.86	90.23	91.70	93.45	94.76	96.18
En Yüksek 40% Özdeğerli TBA Öznitelikleri	5	10	15	20	30	50
Indian Pine (9 sınıf)	43.17	54.24	57.81	62.01	65.36	70.31
Indian Pine (16 sınıf)	40.58	46.87	48.97	—	—	—
DC Mall	73.87	92.16	95.24	97.39	98.34	98.98
En Yüksek 40% Özdeğerli ÇTBA Öznitelikleri	5	10	15	20	30	50
Indian Pine (9 sınıf)	48.44	57.49	62.17	64.05	69.73	73.47
Indian Pine (16 sınıf)	43.09	52.09	56.74	—	—	—
DC Mall	79.01	93.77	96.31	98.39	98.86	99.37

Çizelge 3.4 Farklı eğitim örnekleri ile 9 sınıflı *Indian Pine* verisinde elde edilen genel sınıflandırma doğrulukları (%)

Eğitim Örnekleri Sayısı						
	5	10	15	20	30	50
FKD	38.51	45.37	49.81	57.91	58.36	60.73
ÇFKD _{RTF}	62.41	66.73	71.58	76.07	84.06	90.10
ÇFKD _{laplace}	67.29	73.00	74.65	81.17	86.93	92.60
ÇFKD _{cauchy}	58.33	66.68	71.99	78.14	86.93	78.76
ÇFKD _{log}	64.26	70.03	77.06	82.54	86.44	89.14

FKD ve ÇFKD yöntemlerinin 16 sınıflı *Indian Pine* verisine uygulanması ile elde edilen sonuçlar Çizelge 3.5’de sunulmuştur.

Çizelge 3.5 Farklı eğitim örnekleri ile 16 sınıflı *Indian Pine* verisinde elde edilen genel sınıflandırma doğrulukları (%)

	Eğitim Örnekleri Sayısı					
	5	10	15	20	30	50
FKD	33.25	37.65	46.25	—	—	—
ÇFKD _{RTF}	57.72	65.79	69.88	—	—	—
ÇFKD _{Laplace}	61.44	70.65	71.21	—	—	—
ÇFKD _{cauchy}	61.30	61.82	73.05	—	—	—
ÇFKD _{log}	65.26	69.33	77.43	—	—	—

Son olarak, FKD ve ÇFKD yöntemlerinin *DC Mall* verisine uygulanması ile elde edilen sonuçlar Çizelge 3.6’da sunulmuştur.

Çizelge 3.6 Farklı eğitim örnekleri ile *DC Mall* verisinde elde edilen genel sınıflandırma doğrulukları (%)


	Eğitim Örnekleri Sayısı					
	5	10	15	20	30	50
FKD	79.72	91.50	97.65	94.85	96.05	99.07
ÇFKD _{RTF}	96.18	96.89	97.37	98.25	99.24	99.90
ÇFKD _{Laplace}	97.95	96.51	98.79	96.48	99.33	99.85
ÇFKD _{cauchy}	88.01	93.92	86.87	91.69	96.70	97.15
ÇFKD _{log}	85.65	88.25	92.95	97.32	97.89	97.47

Çizelge 3.4, Çizelge 3.5 ve Çizelge 3.6 ile verilen sonuçlar doğrultusunda, Laplace, Cauchy ve logaritmik çekirdeklerin uygulandığı ÇFKD yöntemlerinin bazı istisnalar dışında DVM yaklaşımından üstün olduğu söylenebilir. Ek olarak, genel sınıflandırma doğruluğunun örnek sayısı ile artması, eğitim kümesi boyutunun sınıflandırma doğruluğu üzerinde küçük örnek durumunda dahi pozitif etki göstermesi sonucunu desteklemiştir. Elbette, istatistiksel yöntemlerin genel bir dezavantajı olarak gereğinden fazla eğitim örneğinin aşırı öğrenmeye yol açacağı da unutulmamalıdır. Son olarak, tüm çekirdek yöntemlerin klasik FKD’ye göre daha iyi sonuçlar ürettiği vurgulanabilir.

ÇFKD ile Gıda Kontrolü: Gıda güvenliği, günümüzde halkın tüm kesimlerini ilgilendiren önemli bir sorundur. Bu nedenle, ürünlerin sağlığını ve güvenliğini kontrol eden gürbüz ve etkili tekniklerin geliştirilmesi önem arz etmektedir. HGS, gıda kalitesi ve güvenliğinin ölçülmesi amacıyla araştırmacıların ilgisini çekmektedir. Örneğin et kalitesinin değerlendirilmesi, balık tazeliği ve kalitesinin değerlendirilmesi, kavunda şeker dağılımının görselleştirilmesi, buğday çekirdeklerinin sınıflandırılması, domateslerin olgunluğunun belirlenmesi, salatalıklarda kusur tespiti ve çilekte çürük tespiti gibi uygulamalarda hiperspektral görüntülemenin imkânlarından faydalanılmıştır.


Gıda güvenliğinin kapsamını fiziksel (doku, renk vs.), kimyasal (yağ içeriği, protein içeriği, pH vs.) ve biyolojik (bakteri sayısı vs.) etkileşimler oluşturmaktadır. Güvenlik ve kalitenin kontrolü genellikle klasik görsel incelemenin yanında kimyasal ve biyolojik analizlerle gerçekleştirilmektedir. Bu yaklaşım yorucu, yavaş ve materyalin yapısını bozucu nitelikte olabilmektedir. Alternatif bir yaklaşım olarak, HGS materyallerden spektral ve uzamsal bilgiyi eşzamanlı olarak üretebilmektedir. Bu yolla, bilgisayarla görmenin de avantajları kullanılarak, işlemlerin daha hızlı ve daha az insan faktörü etkisiyle yürütülmesinin yanında, incelenen materyale zarar verilmeden sonuç alınması da sağlanmaktadır.

Bu kısımda, hiperspektral görüntüleme ile elde edilmiş kıyma eti görüntüsünden yağ içeriğinin tespit edilmesi için ÇFKD yönteminin uygulanmasından bahsedilmiştir. İki-sınıflı yapısından dolayı et ve yağ ayrımı için elverişli olduğu düşünülen ÇFKD, farklı kontrol grupları üzerinde denenmiş ve yağ dokusunun hedef sınıf olarak alındığı deneylerde uygulanmıştır. Laboratuvar ortamında oluşturduğumuz hiperspektral görüntüleme sisteminin şematik diyagramı Şekil 3.6'da verilmiştir. SPECIM (*SPECTral IMaging*) algılayıcılarının kullanıldığı bu deneylerde görünür ve yakın kızılötesi dalga boylarında 196 bant kaydedilmiş ve gürültülü bantların atılmasıyla geriye kalan 187 kanal deneylerde kullanılmıştır. Algoritma performansının değerlendirilmesi için farklı oranlarda karıştırılmış et ve yağ içeren 3 farklı kıyma etinin görüntüsü alınmıştır. Ham hiperspektral veri yansıma verisine dönüştürülmüş ve ön işleme olarak görüntünün kıyma içermeyen kısımlarından kırılmıştır.

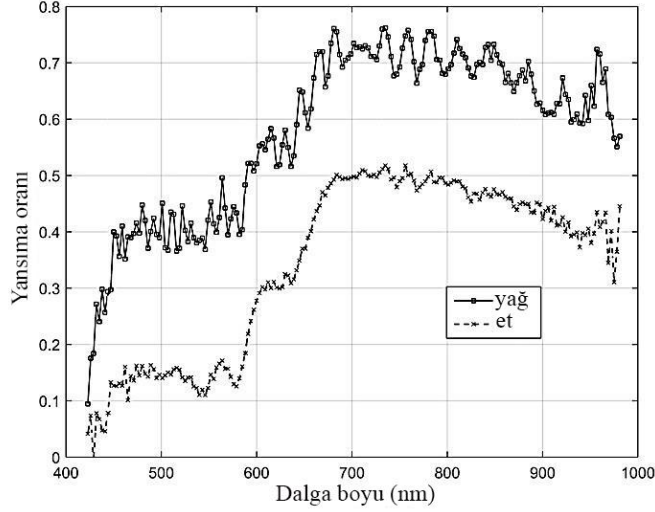


Şekil 3.6 Hiperspektral görüntüleme sisteminin şematik diyagramı

Farklı oranlarda et ve yağ bileşimi içeren kıyma görüntülerinden yaklaşık %64 yağ içerenine ait üç adet tek bantlı görüntü ve bu üç görüntünün birleşiminden oluşan renkli görüntü Şekil 3.7’de verilmiştir. Eğitim verisi olarak saf et ve yağ içeren ayrı bir görüntü üzerinden örnekler toplanmıştır. Sınıfları temsilen örnek birer spektral imza Şekil 3.8’de gösterilmiştir.



Şekil 3.7 Kıyma eti görüntüleri: (a) RGB, (b) 460 nm, (c) 550 nm, (d) 640 nm



Şekil 3.8 Kıyma etine ait örnek spektral imzalar

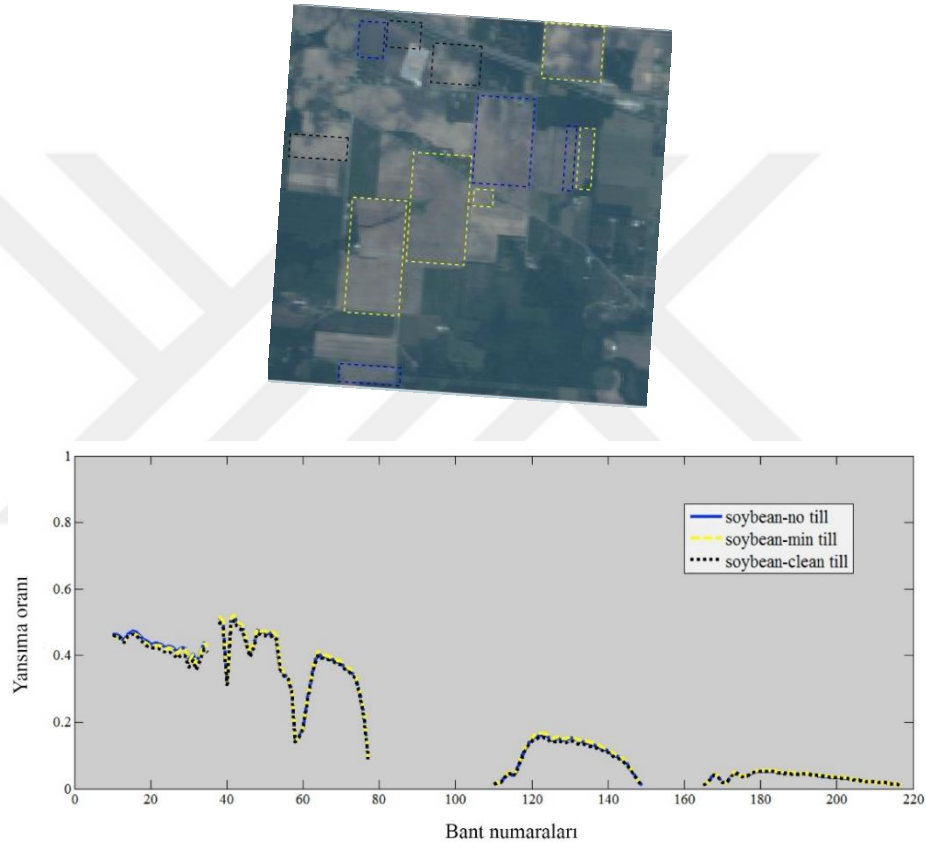
ÇFKD algoritmasının oluşturulması için RTF çekirdek kullanılmış ve bağımsız parametre σ seçimi için tez kapsamında önerilen çekirdek parametresi seçimi prosedürü uygulanmıştır. Yağ örneklerinin hedef sınıf olarak alındığı deneyde, test görüntüleri üzerinde yağ bölgelerinin tahmin edilmesinin ardından kullanıcı tarafından belirlenen bir eşik değeri ile test görüntüsünün yağ ve yağ-değil olarak ikiye bölütlenmesi gerçekleştirilmiştir. Bu aşamadan sonra, tahmin edilen yağ bölgesi tüm kıyma alanı ile oranlanarak algoritma tarafından kestirilen yağ yüzdesi elde edilmiştir. Gerçek yağ yüzdeleri ile önerilen yaklaşım tarafından tahmin edilen oranlar Çizelge 3.7'de verilmiştir.

Çizelge 3.7 Yağ içeriğinin gerçek ve tahmin edilen yüzdeleri

Veri	Gerçek Yüzde	Yöntemin Tahmini
VNIR – 187 bant	37.50	39.21
VNIR – 187 bant	54.55	52.16
VNIR – 187 bant	64.29	63.53

Çizelge 3.7 ile verilen sonuçlar önerilen yaklaşımın gerçek oranlara oldukça yakın tahminler ürettiğini göstermektedir. Genel olarak önerilen eğitici yöntemin bilgisayarla görme tabanlı bir gıda kontrolü uygulaması için etkili olduğu söylenebilir. Bu uygulama, yalnız kıyma etine ait sonuçları içerse de, elbette, öncelikle iki-sınıflı yapıya sahip olmak üzere diğer gıda güvenliği uygulamalarında da kullanılabilir niteliktedir.

Kompozisyonel Çekirdek Birleşimi: ÇFKD üzerinde uygulanan kompozisyonel çekirdek birleşiminin performansını değerlendirmek için iki hiperspektral veri kullanılmıştır. İlki AVIRIS *Indian Pine* verisidir. Orijinalinde 220 spektral banda (0.4-2.5 μm aralığında 10-nm spektral çözünürlük) sahip olan veri, gürültülü ve su buharı etkisindeki bantların elenmesiyle [59], [60], kalan 159 bant üzerinden deneylerde kullanılmıştır. Deneylerde kullanılan ve birbirlerine benzerlikleri nedeniyle ayırt edilmesi güç sınıflar hiperspektral sahne üzerinde gösterilmiş ve veri-içi rasgele 50 örnek ortalaması ile temsil edilmiş spektral imzaları Şekil 3.9’da verilmiştir.



Şekil 3.9 AVIRIS algılayıcıları ile alınmış kuzeybatı Tippecanoe, Indiana test alanı (üst)
Seçilmiş üç sınıf için rasgele toplanan 50 örnek ortalaması ile elde edilmiş spektral vektörler (alt)

İkinci veri kümesi Rochester Institute of Technology tarafından web tabanlı hedef tespiti algoritmalarının test edilmesi amacıyla oluşturulmuş bir proje [61] kapsamında sağlanan HyMap hava platformu verisidir. Görüntü 280×800 piksel uzamsal boyutlara ve VNIR–SWIR bölgesinde 126 spektral kanala sahiptir. Deneylerde 1320–1410 ve 1800–1980 nm aralıkları su buharı soğurmasından dolayı ihmal edilmiştir. Veri üzerinde yer-doğruluğu verilmiş üç adet insan yapımı araç bulunmaktadır (Şekil 3.10)



Şekil 3.10 HyMap hiperspektral verisinin bir kısmı ve V_1 , V_2 , and V_3 hedeflerine ait referans ilgi alanları ile doğrulama fotoğrafları. Hiperspektral küp {R:40, G:23, B:10} kanalları ile sahte renklendirilmiştir.


Hedef sınıf eğitim örnekleri sayısının, parametre seçimi algoritmasına etkisini incelemek amacıyla 3 farklı durum {10, 20, 30} için testler gerçekleştirilmiştir ki bu değerler *soybean-no till* için sırasıyla yaklaşık yüzde 1, 2 ve 3'e, *soybean-clean till* için ise yaklaşık yüzde 1.5, 3 ve 4.5'a karşılık gelmektedir. ÇFKD için optimum σ değeri tek olduğundan DG algoritmasında çaprazlama uygulanmamıştır. Diğer parametreler, $0 < \sigma < 0.5$ aralığı için NP ve F sırasıyla 25 ve 0.3 olarak atanmıştır. Kompozisyonel birleşimli ÇFKD (KB-ÇFKD) durumunda iki σ değeri aranmaktadır (çaprazlama oranı: 0.5). Çizelge 3.8 RTF çekirdek için parametre seçimi sonuçlarını ve seçilen parametreler için çalışmada bahsedilen algoritmalarla üretilen geri getirme oranı-yanlış alarm oranı (GGO-YAO) eğrisi altında kalan alanları (EAA) vermektedir. Ayrıca, önerilen parametre seçimi algoritmasının tek parametre tahmini için harcadığı süre de iki sınıf için ortalama olarak verilmiştir.

İki hiperspektral veri setinde yerleştirilmiş ve doğal hedefler için hedef tespiti performansları araştırılmıştır. Doğal hedefler için *Indian Pine* veri setinden seçilmiş ve ayrılabilirlikleri güç olan üç bitki sınıfı üzerinde deneyler gerçekleştirilmiştir. Tespit performansını değerlendirmek için GGO-YAO eğrileri kullanılmıştır.

Çizelge 3.8 DGA ile elde edilen RTF parametreleri ve ÇFKD ile KB-ÇFKD yöntemlerinin karşılaştırması

Eğitim Örneği Sayısı	Hedef	Süre (s)	Tek çekirdek σ	EAA (%)	KB σ_1 / σ_2	EAA (%)
10	soybean-no till	48.65 \pm 0.24	0.1164	82.81	0.1246 / 0.1104	85.49
	soyben-clean till		0.1501	76.79	0.1094 / 0.1341	80.83
20	soybean-no till	71.15 \pm 0.33	0.1245	83.85	0.1204 / 0.1171	85.08
	soyben-clean till		0.1211	79.45	0.1316 / 0.1324	82.33
30	soybean-no till	176.33 \pm 0.70	0.1185	86.10	0.1161 / 0.1158	88.67
	soyben-clean till		0.1287	79.40	0.1135 / 0.1291	81.45

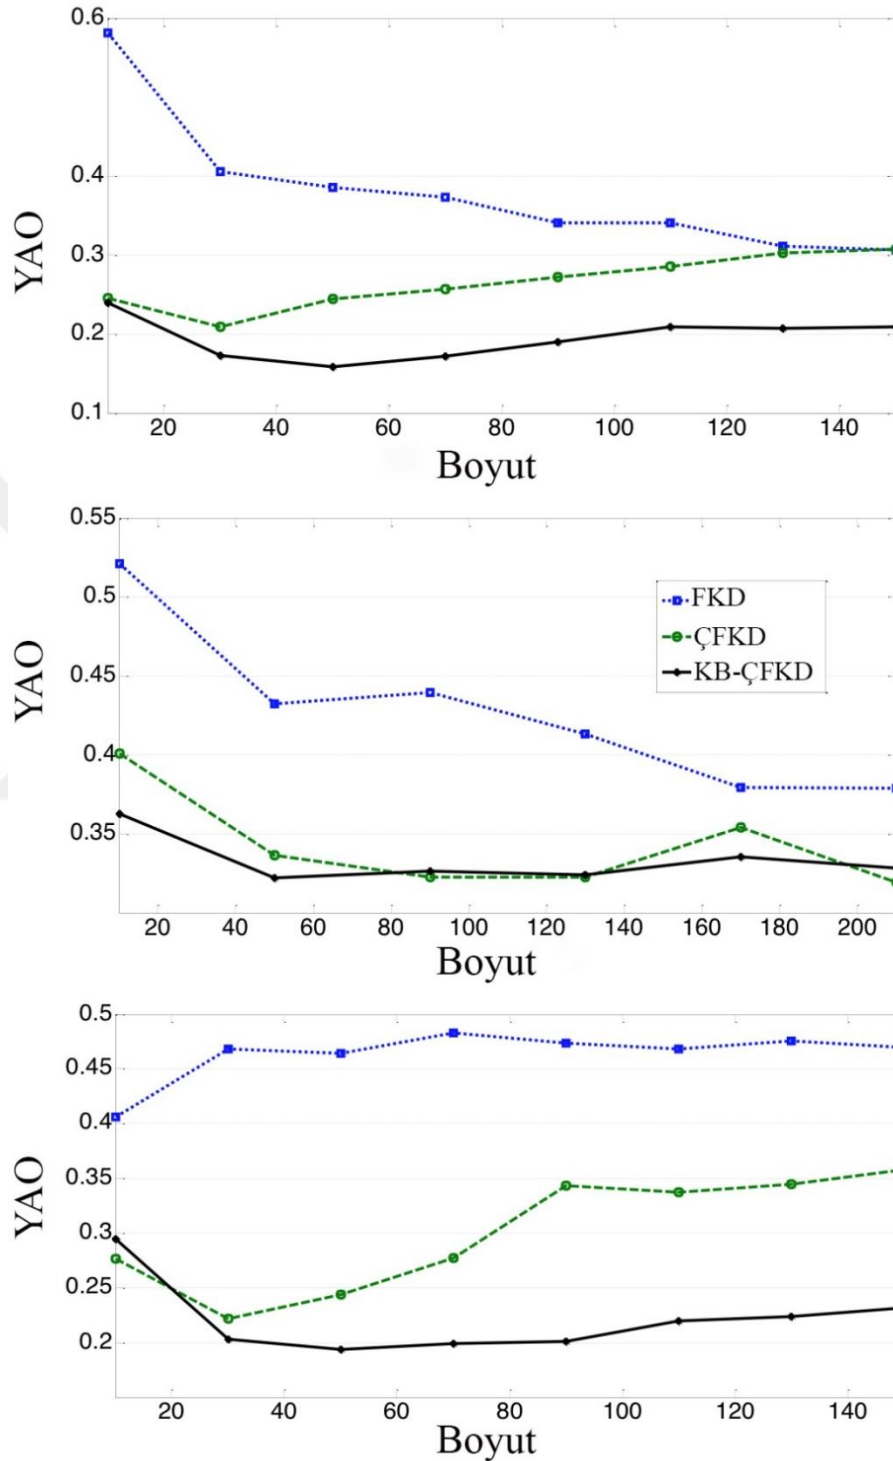
Bir hedef tespiti algoritmasının etkinliğinin önemli bir ölçütü düşük YAO olduğundan, eğrilerin x-ekseninde belirli bölümleri gözlemlenmiştir. ÇFKD ve KB-ÇFKD için uygun σ değerleri her defasında DGA ile belirlenmiştir. Şekil 3.11, bu çalışmada bahsedilen algoritmaların ürettiği geri getirme oranı ve yanlış alarm oranları ile üretilen GGO-YAO eğrilerini göstermektedir. Bu deneylerde doğal hedeflerden rasgele 30 örnek eğitim için seçilmiştir.



Şekil 3.11 *Indian Pine* veri kümesi *soybean-no till* (sol), *soybean-min till* (orta) ve *soybean-clean till* (sağ) sınıfları için üretilmiş GGO-YAO eğrileri


Şekil 3.11 incelendiğinde KB-ÇFKD algoritmasının diğer yöntemlere göre GGO-YAO eğrisi performansı açısından daha başarılı olduğu görülecektir. Eğitim kümesi boyutunun tespit performansına etkisini incelemek için yanlış alarm oranlarının 10 deney için farklı

eđitim veri boyutlarında ortalamaları alınmıřtır. řekil 3.12 ile verilen bu deneyin sonuřları da önerilen yaklařımın klasik versiyonlarına göre üstünlüğünü ortaya koymaktadır.




řekil 3.12 *Indian Pine* veri kümesi *soybean-no till* (üst), *soybean-min till* (orta) ve *soybean-clean till* (alt) sınıfları için YAO (10 deney ortalaması) deđerlerinin eđitim örnekleri sayısı ile deđiřimi

HyMap veri kümesinde insan-yapımı hedeflerin tespit sonuçlarının performanslarını değerlendirmek için hedef yerleştirme metodu kullanılmıştır. Tüm hedefler kendi orijinal yerlerinin dışında Şekil 3.13(a)'da gösterilen 20 bölgeye yerleştirilmiştir. Spektral kütüphaneden alınmış hedef spektral imzaları Şekil 3.13(b)'de verilmiştir. Sınıf içi çeşitlilikleri sağlamak amacıyla hedef spektralarına SNR değeri 20 ile 30 dB arasında rasgele seçilecek şekilde toplamsal beyaz Gauss gürültüsü (AWGN) eklenmiştir. Ayrıca, veri üzerindeki üzerindeki rasgele gürültünün algoritma performansına etkisini incelemek için de verideki tüm bantlara AWGN eklenerek orijinal verinin yanı sıra iki tane daha veri kümesi türetilmiştir. Bu iki gürültülü veri setinden ilki ortalaması 15 dB olacak şekilde 10-20 dB arasından rastgele seçilen SNR değerleriyle, ikincisi ise ortalaması 10 dB olacak şekilde 5-15 dB arasından rastgele seçilen SNR değerleriyle oluşturulmuştur.



Şekil 3.13 HyMap verisi hedef tespiti senaryosu (a) HyMap veri kümesinde yerleştirilmiş hedef yerleri (b) Spektral kütüphaneden alınmış spektral imzalar

Yerleştirilmiş hedefler için tespit performansları, her bir veri üzerinde algoritmaların GGO ve YAO değerleri karşılaştırılarak değerlendirilmiştir. Deneylerde her bir hedefi temsilen rasgele seçilen beş hedef spektrası eğitim için kullanılmıştır. Örnek olarak, Şekil 3.14(b)-(d) yerleştirilmiş hedef V_1 için KB-ÇFKD kullanılarak üretilmiş tespit sonuçlarını göstermektedir.



Şekil 3.14 V_1 hedefi için KB-ÇFKD algoritması tespit sonuçlarının gösterimi. (a) Doğrulama verisi (b) Orijinal veri sonucu (c) Gürültülü veri (SNR: 15 dB) sonucu (d) Gürültülü veri (SNR: 10 dB) sonucu

Detaylı tespit performansları Çizelge 3.9’da verilmiştir. Sonuçlar incelendiğinde, önerilen yöntemin her üç yerleştirilmiş hedef sınıfı için de üstün bir performans gösterdiği söylenebilir. Bu kısımda, ÇFKD için tek bir çekirdek seçimi yerine kompozisyonel çekirdek birleşimi yaklaşımının uygulanması üzerinde durulmuş ve hiperspektral görüntülerde hedef tespiti deneyleri ile önerilen algoritma test edilmiştir. Ayrıca, ÇFKD ve önerilen KB-ÇFKD için daha önce çalışılmamış olan çekirdek parametre seçimi üzerinde de incelemeler yapılmış ve diferansiyel gelişim algoritması tabanlı bir optimizasyon problemi oluşturulmuştur. Önerilen algoritma ve klasik versiyonları ile birlikte bu raporda anlatılan üç yöntem iki farklı hiperspektral veri üzerinde hedef tespiti performansları açısından karşılaştırılmıştır. Çizelge 3.9, teorik çıkarımlara paralel olarak önerilen yöntemin diğer yaklaşımlardan üstün olduğunu ortaya koymuştur.

Çizelge 3.9 Algoritmaların GGO ve YAO değerleri

	Orijinal			Gürültülü (15 dB)			Gürültülü (10 dB)		
	GGO	YAO	GGO	YAO	GGO	YAO	GGO	YAO	
V_1									
FKD	$0.7940 \pm 2.95 \times 10^{-2}$	$0.6296 \pm 4.52 \times 10^{-2}$	$0.7586 \pm 8.55 \times 10^{-2}$	$0.6581 \pm 5.67 \times 10^{-2}$	$0.5714 \pm 4.76 \times 10^{-2}$	$0.7926 \pm 5.23 \times 10^{-2}$			
ÇFKD	1	$1.3 \times 10^{-3} \pm 0.002$	$0.989 \pm 1 \times 10^{-3}$	$1 \times 10^{-3} \pm 0.001$	$0.953 \pm 2 \times 10^{-3}$	$9.1 \times 10^{-2} \pm 0.001$			
KB-ÇFKD	1	0	1	$2.3 \times 10^{-4} \pm 1.2 \times 10^{-4}$	$0.991 \pm 1.7 \times 10^{-3}$	$3.44 \times 10^{-4} \pm 6.3 \times 10^{-5}$			
FKD	$0.8162 \pm 4.9 \times 10^{-2}$	$0.5473 \pm 1.36 \times 10^{-1}$	$0.7619 \pm 4.76 \times 10^{-2}$	$0.6013 \pm 5.79 \times 10^{-2}$	$0.6032 \pm 7.28 \times 10^{-2}$	$0.7134 \pm 7.66 \times 10^{-2}$			
V_2									
ÇFKD	1	0	$0.9925 \pm 7.8 \times 10^{-3}$	$1 \times 10^{-4} \pm 2 \times 10^{-5}$	$0.9551 \pm 4.2 \times 10^{-3}$	$7.11 \times 10^{-4} \pm 1.69 \times 10^{-5}$			
KB-ÇFKD	1	0	1	0	$0.983 \pm 1 \times 10^{-4}$	$5.16 \times 10^{-5} \pm 1 \times 10^{-5}$			
FKD	$0.7778 \pm 5.5 \times 10^{-2}$	$0.5584 \pm 1.869 \times 10^{-1}$	$0.7301 \pm 9.91 \times 10^{-2}$	$0.6719 \pm 5.46 \times 10^{-2}$	$0.6667 \pm 1.26 \times 10^{-1}$	$0.7264 \pm 7.74 \times 10^{-2}$			
V_3									
ÇFKD	1	$1.78 \times 10^{-5} \pm 1.18 \times 10^{-5}$	1	$4.017 \times 10^{-5} \pm 4.25 \times 10^{-5}$	$0.9525 \pm 7.07 \times 10^{-4}$	$4.17 \times 10^{-4} \pm 1.85 \times 10^{-5}$			
KB-ÇFKD	1	0	1	0	$0.988 \pm 6.1 \times 10^{-4}$	$1.07 \times 10^{-4} \pm 1 \times 10^{-5}$			

Bileşik Çekirdekler: Bileşik çekirdeklerin performansını değerlendirmek için, *Indian Pine* (Şekil 3.4) verisi üzerinde testler gerçekleştirilmiştir. Her bir sınıftan rasgele 10 örnek eğitim için kullanılmış, her defasında geri kalan gruplardan eşit sayıda toplamda 10 örnek alınmıştır. Çekirdek parametreleri deneysel olarak belirlenmiş ve testler 50 kere tekrarlanmıştır. Çizelge 3.10 GGO-YAO eğrileri altında kalan alanları ortalama ve standart sapma şeklinde yüzdesel olarak vermektedir. BÇ yaklaşımı ile genel olarak daha iyi sonuçlar alınsa da belirgin bir performans artışının sağlanamadığı görülmektedir.

Çizelge 3.10 Tek ve bileşik çekirdekler için GGO-YAO eğrisi altında kalan alanlar (%)

Sınıf	Spektral		Uzamsal (μ , 5 x 5 pencere)	Bileşik	
	K_{λ} - Cauchy	K_S^{μ} - RTF		$K_{\lambda} + K_S^{\mu}$ (5x5)	$p * K_{\lambda} + (1-p) * K_S^{\mu}$
Alfalfa	98.92 ± 0.32	97.23 ± 2.03		98.68 ± 0.40	98.95 ± 0.25 (p = 0.9)
Corn-no till	76.07 ± 2.79	70.49 ± 3.67		77.35 ± 3.25	76.99 ± 2.93 (p = 0.6)
Corn-min till	80.14 ± 2.45	77.02 ± 3.04		80.06 ± 2.11	80.95 ± 1.85 (p = 0.9)
Corn	87.90 ± 5.15	84.79 ± 3.51		90.81 ± 3.15	91.28 ± 2.96 (p = 0.3)
Grass-pasture	94.10 ± 1.30	85.69 ± 6.30		93.79 ± 2.53	94.49 ± 0.88 (p = 0.2)
Grass-trees	97.20 ± 1.36	93.98 ± 1.48		98.07 ± 0.93	97.83 ± 1.21 (p = 0.6)
Grass-past. mow.	98.94 ± 0.82	99.38 ± 0.82		99.97 ± 0.02	99.92 ± 0.12 (p = 0.1)
Hay-windr.	99.62 ± 0.30	97.28 ± 2.25		99.69 ± 0.17	99.70 ± 0.11 (p = 0.6)
Oats	99.53 ± 0.28	99.90 ± 0.09		99.98 ± 0.02	99.91 ± 0.06 (p = 0.4)
Soybean-no till	86.17 ± 3.07	83.34 ± 3.88		86.80 ± 3.02	88.65 ± 2.49 (p = 0.6)
Soybean-min t.	84.12 ± 1.48	80.66 ± 3.06		84.16 ± 1.86	84.40 ± 0.85 (p = 0.1)
Soybean-clean t.	80.22 ± 3.68	68.18 ± 3.85		77.00 ± 5.90	80.49 ± 6.02 (p = 0.4)
Wheat	99.61 ± 0.09	99.34 ± 0.81		99.77 ± 0.10	99.71 ± 0.11 (p = 0.5)
Woods	98.05 ± 0.50	92.80 ± 2.93		98.40 ± 0.26	98.07 ± 0.86 (p = 0.4)
Bldg-Grass-Tree-D.	86.93 ± 1.26	85.37 ± 3.68		91.03 ± 1.63	89.97 ± 1.25 (p = 0.4)
Stone-steel twrs	96.34 ± 2.67	94.41 ± 3.69		97.91 ± 2.05	97.26 ± 2.39 (p = 0.6)

TÖ ile Çoklu-çekirdek Öğrenmesi: TÖ yaklaşımı ile çoklu-çekirdek öğrenmesi (ÇÇÖ) görevinin yerine getirilmesi ve ÇFKD ile uygulanması için ağırlıklı ve ağırlıksız oylama teknikleri kullanılmıştır. Önceden seçilmiş belirli bir çekirdek kullanılarak üretilmiş her bir ÇFKD alt-sınıflandırıcı olarak kabul edilerek, bu alt-sınıflandırıcıların test örneği üzerindeki tahminleri TÖ ile birleştirilmiştir. ÇFKD yönteminin iki-sınıflı yapısı dikkate alınarak Eşitlik 3.41 ve 3.42 yeniden yazılırsa, ağırlıksız oylama Eşitlik 3.49 ile verilir.

$$f_{i,ağırlıksız} = \begin{cases} -1, & \frac{1}{M} \sum_{k=1}^M f_{i,ÇFKD}^k < 0 \\ 1, & \frac{1}{M} \sum_{k=1}^M f_{i,ÇFKD}^k \geq 0 \end{cases} \quad (3.49)$$

Burada M , alt-sınıflandırıcıların sayısını ve $f_{i,ağırlıksız}(\cdot)$, i test örneğine ait son kararı belirtmektedir. En kolay ve hızlı birleştirme yöntemi olmasının yanında, ağırlıksız oylamanın her zaman istenen performansı gösteremeyeceği açıktır. Ağırlıksız oylamanın aksine ağırlıklı oylamada, her alt-sınıflandırıcının nihai kararı çeşitli yollarla hesaplanmış bir katsayı ile ağırlıklandırılır.

$$f_{i,ağırlıklı} = \begin{cases} -1, & \frac{1}{M} \sum_{k=1}^M w_k f_{i,ÇFKD}^k < 0 \\ 1, & \frac{1}{M} \sum_{k=1}^M w_k f_{i,ÇFKD}^k \geq 0 \end{cases} \quad (3.50)$$

Burada w_k , belirlenmesi gereken ağırlık katsayılarıdır. Uygun katsayı değerlerinin belirlenmesi, istenen performansı elde etmek için önemli bir adımdır [20]. Genel olarak, alt-sınıflandırıcının eğitim kümesi üzerindeki doğruluğu ile orantılı bir katsayı tercih edilebilmektedir [62]. Buradan hareketle uygulanan ağırlık katsayıları Eşitlik 3.51 ile hesaplanmıştır.

$$w_k = \frac{1}{N} \sum_{k=1}^N (f_{DV} \times f_k) \quad (3.51)$$

Burada, N eğitim kümesindeki eleman sayısını, f_{DV} bu örneklerin gerçek etiketlerini (doğrulama verisi) ve f_k ise alt-sınıflandırıcının tahminini temsil etmektedir. Alt-sınıflandırıcının doğru etiketlediği örneklerin sayısı arttıkça, Eşitlik 3.51 ile hesaplanan ağırlık katsayısı da artacaktır.

Geliştirilen algoritma University of California, Irvine (UCI) [63] veri havuzundan alınmış iki-sınıflı dört adet karşılaştırma verisi (İyonosfer, Wisconsin meme kanseri (orijinal, WMKO), sonar, deri) üzerinde test edilmiştir. Kullanılan veriler hakkında özet bilgi Çizelge 3.11'de verilmiştir.

Çizelge 3.11 Kullanılan veriler hakkında özet bilgi

Veri	Sınıf Sayısı	Örnek Sayısı	Öznitelik Sayısı
İyonosfer	2	351	33
Wisconsin Meme Kanseri (Orijinal)	2	683	9
Sonar	2	208	59
Deri	2	245057	3

Sınıflandırma performansı sınıflandırma doğruluğu ve Kappa katsayısı [30] kullanılarak değerlendirilmiştir. Cohen'in Kappa katsayısı olarak da bilinen bu ölçüt iki sınıflandırıcı/karar verici arasındaki karşılaştırmalı uyuşmanın güvenilirliğini ölçen bir istatistik yöntemidir [31]. 1 ve 1'den küçük değerler alabilen bu katsayının 1 değerini alması mükemmel uyuşmayı, 0 değerini alması ise bir şans uyuşmasını göstermektedir. Kappa katsayısı uyuşmanın bir şans eseri olabileceğini de dikkate aldığından, klasik yüzde orantı olarak bulunan uyuşmadan özellikle sınıflar arası nüfus dengesizliği olduğu durumlarda daha güçlü ve anlamlı bir sonuç verdiği kabul edilmektedir. Kappa ölçütü (κ) klasik karışıklık matrisi elemanları kullanılarak hesaplanabilir.

$$\kappa = \frac{\text{sınıflandırma doğruluğu} - \text{rasgele doğruluk}}{1 - \text{rasgele doğruluk}} \quad (3.52)$$

Burada, bilindiği gibi sınıflandırma doğruluğu karışıklık matrisinin diyagonal değerlerinin toplamının, tüm değerlerin toplamına bölünmesiyle bulunur.

$$\text{sınıflandırma doğruluğu} = \frac{DP+DN}{DP+DN+YP+YN} \quad (3.53)$$

Eşitlik 3.53'de, DP doğru pozitiflerin, DN doğru negatiflerin, YP yanlış pozitiflerin ve YN yanlış negatiflerin sayısıdır. Yine karışıklık matrisi elemanları cinsinden rasgele doğruluk ise:

$$\text{rasgele doğruluk} = \frac{[(YP+DN) \times (DN+YN)] + [(YN+DP) \times (YP+DP)]}{\text{toplam} \times \text{toplam}} \quad (3.54)$$

ile verilir. Bu ifadede, problemde ele alınan toplam eleman sayısı toplam olarak kısaltılarak verilmiştir.

Her bir veri için radyal tabanlı fonksiyon (RTF) ve küresel çekirdekler ayrı ayrı kullanılarak deneyler gerçekleştirilmiştir (Çizelge 3.12).

Çizelge 3.12 Kullanılan çekirdekler

Çekirdek	Formül
RTF	$K_{RTF}(\mathbf{x}, \mathbf{y}) = \exp(-\ \mathbf{x} - \mathbf{y}\ ^2/2\sigma^2)$
Küresel	$K_{Küresel}(\mathbf{x}, \mathbf{y}) = 1 - 3/2 \frac{\ \mathbf{x} - \mathbf{y}\ }{\sigma} + 1/2 \left(\frac{\ \mathbf{x} - \mathbf{y}\ }{\sigma} \right)^3$

Çekirdekler 21 ayrı parametre kullanılarak oluşturulmuş ve her bir ayrı parametre ile üretilen sınıflandırıcı bir alt-sınıflandırıcı olarak uygulanmıştır. RTF çekirdek için bu parametreler; $\{\dots, \sigma_0 - 0.2, \sigma_0 - 0.1, \sigma_0, \sigma_0 + 0.1, \sigma_0 + 0.2, \dots\}$, küresel çekirdek için ise $\{\sigma_0, \sigma_0 + 0.2, \sigma_0 + 0.4, \dots\}$ olarak seçilmiştir. Merkezi parametre σ_0 her iki çekirdek için Eşitlik 3.55 ile hesaplanmıştır.

$$\sigma_0 = \sqrt{\sum_N \|x^k - \bar{x}\|^2 / N} \quad (3.55)$$

Burada \bar{x} , N adet örnek içeren eğitim kümesinin ortalamasını vermektedir. Eğitim kümesi her denemede önceden belirlenmiş sabit bir oran kadar rasgele seçilmiştir. Örnek sayısı görece fazla olan *deri* verisi için bu oran %0.1 diğerleri için ise %10 olarak alınmıştır.

Çizelge 3.13 RTF çekirdek için 10 bağımsız koşturmaya ait sınıflandırma doğruluğu (%) ve Kappa katsayısı, κ (%) değerleri

Veri	Eğitim Örnekleri Yüzdesi	ÇFKD				TÖ-ÇFKD			
						Ağırlıksız Oylama		Ağırlıklı Oylama	
		Doğruluk	κ	Doğruluk	κ	Doğruluk	κ	Doğruluk	κ
İyonosfer	10	μ	73.84	51.35	80.88	61.98	83.70	66.91	
		std	6.15	9.90	6.99	12.02	4.99	8.85	
WMKO	10	μ	63.15	40.29	58.18	33.00	81.35	67.07	
		std	18.22	27.14	28.23	42.32	21.92	34.63	
Sonar	10	μ	57.93	10.87	57.93	10.64	58.70	12.24	
		std	1.34	2.86	1.23	2.64	1.12	2.54	
Deri	0.1	μ	78.20	24.59	79.80	4.68	98.86	96.61	
		std	2.68	1.23	0.69	5.56	0.35	1.01	

İşlemler birbirinden bağımsız olarak 10 kere tekrar edilmiş ve metriklerin ortalama ve standart sapma değerleri kaydedilmiştir. RTF çekirdekle gerçekleştirilen deneye ait sonuçlar Çizelge 3.13’de verilmiştir. Koyu ile verilen skorlar kazanan durumları göstermektedir. Ağırlıksız oylama ya da çoğunluk oylamasının *iyonosfer* ve *deri* verilerinde performansı artırdığı, bununla birlikte, WMKO verisinde düşürdüğü gözlenmiştir. *Sonar* verisi için konuşursak, ağırlıksız oylama tabanlı TÖ-ÇFKD ile tek çekirdekli ÇFKD arasında sınıflandırma doğruluğu ve Kappa katsayısı açısından önemli bir fark olmadığı söylenebilir. Genel olarak, ağırlıklı oylama ile oluşturulmuş sınıflandırma algoritması seçilen tüm veriler üzerinde en iyi sonucu üretmiştir.

Küresel çekirdek ile üretilen sonuçlar Çizelge 3.14’de verilmiştir. Sonuçlar incelendiğinde, *deri* verisi hariç çoğunluk oylamasının performansı artırdığı görülecektir. RTF çekirdek sonuçlarına benzer olarak, ağırlıklı oylama ile tüm verilerde en iyi sınıflandırma doğruluğu elde edilmiştir.

Çizelge 3.14 Küresel çekirdek için 10 bağımsız koşturmaya ait sınıflandırma doğruluğu (%) ve Kappa katsayısı, κ (%) değerleri

Veri	Eğitim Örnekleri Yüzdesi		ÇFKD			TÖ-ÇFKD			
					Ağırlıksız Oylama		Ağırlıklı Oylama		
			Doğruluk	κ	Doğruluk	κ	Doğruluk	κ	
İyonosfer	10	μ	48.77	15.56	53.42	21.19	57.21	26.16	
		std	1.77	2.46	3.78	5.03	2.48	3.61	
WMKO	10	μ	67.82	45.74	78.57	59.76	84.57	69.51	
		std	5.89	9.35	11.50	17.33	5.51	9.85	
Sonar	10	μ	56.88	8.04	57.31	8.97	57.64	9.73	
		std	0.65	1.47	0.93	2.11	0.27	0.62	
Deri	0.1	μ	70.06	40.71	69.85	40.30	80.53	61.31	
		std	3.05	6.00	5.73	11.21	5.37	10.60	

ÇFKD için Çekirdek Parametresi Seçimi: ÇFKD için çekirdek parametresi seçimi ile ilgili sonuçlara KÇB bölümünde yer verilmişti. Bu kısımda, bağımsız olarak yalnız çekirdek seçimi üzerine gerçekleştirilen bir çalışmanın sonucu sunulmuştur.

Veri olarak *Indian Pine* hiperspektral görüntüsü kullanılmıştır. Görüntü üzerindeki iki zorlu sınıf ile testler gerçekleştirilmiştir. Bu sınıflar hakkında özet bilgi Çizelge 3.15’de verilmiştir.

Çizelge 3.15 Parametre seçimi için test sınıfları

Sınıf	Örnek Sayısı
Hay-windrowed	489
Grass/trees	747

Eğitim örnekleri kümesinin boyutunun önerilen çekirdek seçimi tekniği performansına etkisini incelemek için farklı örnekleme yüzdeleri için algoritma koşturulmuştur. Belirlenmesi gereken tek bir parametre olduğundan DGA algoritmasında çaprazlama adımı ihmal edilmiştir. Karşılaştırma için, literatürde parametre seçimi amacıyla sıkça tercih edilen çapraz-doğrulama yöntemi beş-katlı olarak uygulanmıştır. Her iki yöntem de uygun sigma değerini $\{0, \dots, 2\}$ aralığında ararken, çapraz-doğrulama 0.01 aralıklarla ızgara araması yapmıştır. Yöntemlerin performansı geri getirme oranı-yanlış alarm oranı (GGO-YAO) eğrisi altında kalan alanlar (EAA) cinsinden değerlendirilmiştir. *DC Mall* verisinden seçilmiş bazı sınıflar üzerinde elde edilen karşılaştırmalı sonuçlar Çizelge 3.16’da verilmiştir.

Çizelge 3.16 *Indian Pine* verisi seçilmiş sınıflar için parametre seçme sonuçları

Eğitim Örnekleri Yüzdesi	Sınıf	Çapraz-doğrulama		Önerilen Yöntem	
		Çekirdek Parametresi (σ)	EAA (%)	Çekirdek Parametresi (σ)	EAA (%)
1	Hay-windr.	0.09	92.60	0.1064	93.80
	Grass/tress	0.14	88.41	0.1301	90.79
2	Hay-windr.	0.11	98.13	0.1145	99.01
	Grass/tress	0.14	89.74	0.1288	92.46
3	Hay-windr.	0.11	99.07	0.1105	99.10
	Grass/tress	0.15	94.81	0.1203	98.40

Çizelge 3.16 ile verilen sonuçlar, önerilen yaklaşımın ÇFKD algoritmasında veriye uygun çekirdek parametresinin üretilmesi için kullanışlı olduğunu göstermiştir. 2.3GHz Intel Core i5 işlemcili, 8GB RAM’e sahip bir bilgisayarda MATLAB 8.5 yazılımıyla

gerçekleştirilen deneylerde yöntemlerin hesaplama süreleri de kaydedilmiştir. Belirli eğitim örnekleri yüzdesi için, seçilmiş sınıflara ait çalışma zamanlarının ortalaması karşılaştırmada kullanılmıştır. Çizelge 3.17’de verilen karşılaştırmalı çalışma zamanları dikkate alınarak, önerilen DGA-tabanlı yaklaşımın uygun parametre değerine daha hızlı ulaştığı söylenebilir. Daha kesin bir ifadeyle, önerilen yaklaşımın çapraz-doğrulamadan %2 eğitim örneği seçildiği durumda 5 kat ve %3 seçildiği durumda 11 kat daha hızlı olduğu görülmektedir.

Çizelge 3.17 Yöntemlerin ortalama hesaplama süreleri (saniye)

Eğitim Örnekleri Yüzdesi	Çapraz-doğrulama	Önerilen Yöntem
1	301.16	223.29
2	1174.52	226.04
3	2642.67	227.27

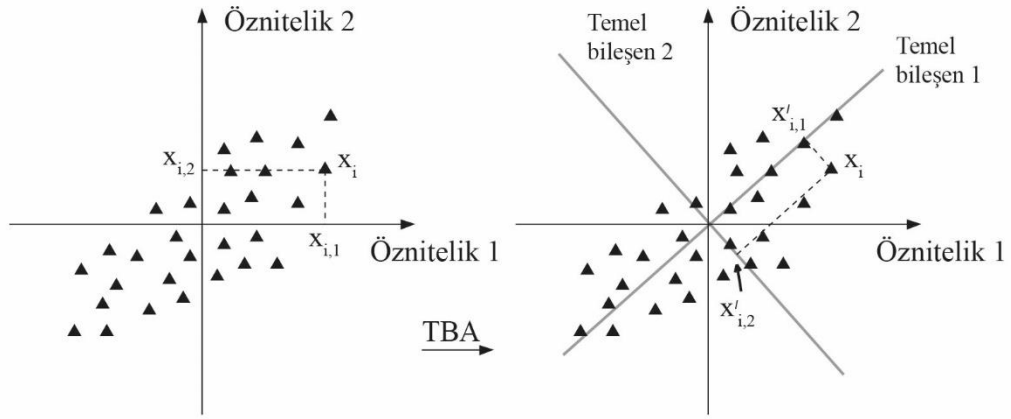
YÜKSEK BOYUTLU VERİLERDE BOYUT AZALTMA

Hiperspektral görüntülerde hızlı ve etkin hedef tespiti/sınıflandırma/kümeleme görevleri için boyut azaltma önemli bir adımdır. Öznitelik seçme ve çıkarma olmak üzere iki farklı şekilde gerçekleştirilebilen boyut azaltma ile hem verideki gereksiz ve ilgisiz bilgi elenmekte hem de sınıf bilgisinin kullanıldığı durumlarda sınıflar arası ayırt edici öznitelikler ortaya çıkarılmaktadır. Özellikle hedef tespiti ve tanıma problemlerinde hedefin ayırt edici özelliklerinin korunarak boyut azaltımı hayati öneme sahip bir ihtiyaçtır.

Bu bölümde, hiperspektral görüntülerde boyut indirgeme için ÇFKD tabanlı bir yöntem sunulmuştur. Önerilen yöntem, hedef ve arka plan karışıklığına ait eğitim örnekleri ile üretilmiş ortak özuzayda hedefi iyi temsil eden belirli oranda özvektörün seçimi ve tüm verinin bu özvektörler üzerine izdüşümünü sağlamaktadır. İlerleyen kısımlarda öncelikle, literatürde sıkça yer alan TBA ve bu yöntemin hiperspektral verilerde öznitelik çıkarımı amaçlı kullanımından bahsedilmiştir. Ardından, yine literatürde mevcut olan FKD ile boyut azaltma yönteminin teorisi anlatılmış ve hiperspektral veriler için yetersizliği vurgulanmıştır. Sonraki kısımda, bu yetersizliğin üstesinden gelmek için önerilen yöntemin teorik altyapısı anlatılmıştır.

4.1 Temel Bileşen Analizi (TBA) ile Boyut Azaltma

Temel bileşen analizi (TBA) [64] ile boyut azaltma, hiperspektral görüntülerde komşu bantların yüksek korelasyonlu olması ve bu nedenle sahne hakkında neredeyse aynı bilgiyi taşıması gerçeğinden hareket etmektedir. TBA bu varsayımı kullanarak, veriyi bantlar arası korelasyonun azalacağı bir dönüşüme uğratmaya çalışmaktadır. Dönüşümün geometrik yorumu Şekil 4.1’de temsilen gösterilmiştir.



Şekil 4.1 Temel bileşen analizinin geometrik yorumu

Orijinal verinin iki boyutlu olduğu bu temsilde, soldaki kısma bakılırsa bantlar arasında gözle görülür bir korelasyon olduğu farkedilecektir. Sağ kısımda, TBA işleme sokulduktan sonra elde edilen TBA bantlarına (temel bileşenler) dikkat edilirse bu korelasyonun kaybolduğu anlaşılır. Dönüşüm, değişiminin yüksek olduğu TBA bandına gerçekleştirilerek verinin indirgenmiş bir formu elde edilir.

Bu dönüşümü bulmak için, TBA, hiperspektral bantların istatistiksel özelliklerini inceler ve birbirlerine olan bağılıklarını veya korelasyonlarını araştırır. Bu haliyle, TBA ile Karhunen-Loève [64] dönüşümü arasında bir benzerlik kurulabilir. Her iki dönüşüm de incelenen verinin kovaryans matrisinin özayrıştırıma tabi tutulmasına dayanmaktadır. Yöntemlerin detaylı analizi için [65] ile verilen çalışma incelenebilir. Bir hiperspektral görüntü pikselinin $\mathbf{x} = [x_1, \dots, x_d]^T$ ile verildiğinden bahsedilmiştir. Hiperspektral küpün bir bandının m_1 satır ve m_2 sütundan oluştuğu kabul edilirse, toplamda $M = m_1 \times m_2$ adet piksel vektörü mevcuttur. Tüm vektörlerin ortalaması Eşitlik 4.1'de verildiği gibi hesaplanır ve gösterilir.

$$\bar{\mathbf{x}} = \frac{1}{M} \sum_{i=1}^M \mathbf{x}_i \quad (4.1)$$

Veri kümesine ait kovaryans matrisi ise Eşitlik 4.2 ile elde edilir.

$$\mathbf{\Sigma} = \frac{1}{M} \sum_{i=1}^M (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})^T \quad (4.2)$$

TBA bu aşamada kovaryans matrisinin özayrıştırmasıyla devam eder.

$$\mathbf{\Sigma} = \mathbf{V}\mathbf{\Lambda}\mathbf{V}^T \quad (4.3)$$

Eşitlik 4.3'de, $\mathbf{\Lambda}$ diyagonal elemanları kovaryans matrisinin özdeğerlerine karşılık gelen matrisi, \mathbf{V} ise kovaryans matrisinin özvektörlerinden oluşan birimdik matrisi temsil

etmektedir. TBA için doğrusal dönüşüm Eşitlik 4.4 ile tanımlanır ve elde edilen bir TBA vektörüdür.

$$\mathbf{y}_i = \mathbf{V}^T \mathbf{x}_i \quad i = 1, \dots, M \quad (4.4)$$

Tüm TBA vektörlerinin birleştirilmesiyle orijinal verinin TBA ile dönüştürülmüş versiyonu elde edilir. Kovaryans matrisi özvektörlerinin, özdeğerlerin azalan sırasına, $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_d$, düzenlendiğini düşünelim. Özvektörler içerisinde seçilecek ilk l ($l < d$) tanesi orijinal görüntünün bir yaklaşıklığının üretilmesinde kullanılır. $d \times d$ boyutlu kovaryans matrisinin özvektörleri \mathbf{v}_k ile gösterilsin. O halde, ilk l özvektör \mathbf{v}_k ($k = 1, \dots, l$) kullanılarak dönüştürülmüş görüntü Eşitlik 4.5 ile hesaplanır.

$$\mathbf{x}_{TBA}^i = \begin{bmatrix} \mathbf{v}_{11} & \mathbf{v}_{12} & \dots & \mathbf{v}_{1l} & \dots & \mathbf{v}_{1d} \\ \mathbf{v}_{21} & \mathbf{v}_{22} & \dots & \mathbf{v}_{2l} & \dots & \mathbf{v}_{2d} \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ \mathbf{v}_{l1} & \mathbf{v}_{l2} & \dots & \mathbf{v}_{ll} & \dots & \mathbf{v}_{ld} \end{bmatrix} \begin{bmatrix} \mathbf{x}_1^i \\ \vdots \\ \mathbf{x}_l^i \\ \vdots \\ \mathbf{x}_d^i \end{bmatrix} \quad (i = 1, \dots, M) \quad (4.5)$$

Bu yolla oluşturulmuş TBA görüntüsü, ilk bandında en yüksek değişimliliğe son bandında ise en düşük değişimliliğe sahiptir. Bu nedenle, ilk l bant orijinal veride yer alan bilginin mümkün olduğunca çoğunluğunu tutmaktadır. Bant sayısı azaltılmış ve görüntüde var olan gürültünün giderilmiş olması bu indirgenmiş veri ile gerçekleştirilen işlemlerin daha hızlı ve yüksek doğrulukta yürütülmesini sağlamaktadır. Bununla birlikte, TBA tüm veri üzerinde eğitici bir işlem yürüttüğünden ve sınıfların ayırt ediciliği üzerinde etkili olabilecek yerel istatistikleri göz ardı ettiğinden, özellikle hedef tespiti ve sınıflandırma uygulamaları için hiperspektral veride dezavantajlı durumdadır [66]. Bu dezavantajı gidermek için, sınıf bilgisinden, yerel bilgiden ve ham özneliklerin doğrusal olmayan ilişkilerinden birine ya da birkaçına aynı anda odaklanan yöntemler tercih edilebilir.

4.2 Fukunaga-Koontz Dönüşümü ile Boyut Azaltma

Bir hiperspektral küp üzerinde işlemler gerçekleştirilirken genelde her bir \mathbf{z} pikseline karşılık gelen d -boyutlu vektörler ele alınır, $\mathbf{z} \in \mathbb{R}^d$. Bu durumda, boyut azaltma görevi için amacımız $\mathbf{W} = [\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_l]$ gibi bir dönüşüm matrisi bulmaktır ki sonuçta veri l -boyuta aktarılır, $l < d$. Bu işlevi gerçekleştirmek üzere her bir örnek için bir dönüşüm yazılabilir:

$$\mathbf{z}' = \mathbf{z}\mathbf{W} \quad (4.6)$$

TBA durumunda \mathbf{W} dönüşüm matrisi, verinin en büyük değışintisi doğrultusundaki birkaç temel bileşen ile elde edilir [67]. FKD ile boyut azaltma için hedef sınıfa ait l adet baskın özvektör kullanılarak Eşitlik 4.7 ile verilen dönüşüm matrisi elde edilir [36].

$$\mathbf{W} = \mathbf{P}\boldsymbol{\Theta}_1 \quad (4.7)$$

Eşitlik 4.7’de $\boldsymbol{\Theta}_1$ hedef sınıfı temsil eden taban fonksiyonları, \mathbf{P} ise dönüşüm operatörüdür (Bkz. Bölüm 3.1). Bu dönüşüm hiperspektral görüntüye uygulandığında, veri, seçilen özvektör sayısı kadar (burada l) boyutlu yeni bir uzaya taşınmış olacaktır.

4.3 Çekirdek Fukunaga-Koontz Dönüşümü ile Boyut Azaltma

Hatırlanacağı üzere, ÇFKD yönteminde FKD’den farklı olarak verinin ham hali üzerinden değil, Hilbert uzayında tanımlanmış bir iç-çarpım sonucu üretilmiş pozitif yarı-tanımlı matrisler üzerinden işlemler sürdürülmektedir. Bölüm 3.2’de yer alan Eşitlik 3.13’den devam edilirse, merkezileştirme işlemi:

$$\tilde{\boldsymbol{\Sigma}}_X^K = \boldsymbol{\Sigma}_X^K - \mathbf{I}_M \boldsymbol{\Sigma}_X^K - \boldsymbol{\Sigma}_X^K \mathbf{I}_M + \mathbf{I}_M \boldsymbol{\Sigma}_X^K \mathbf{I}_M \quad (4.8)$$

Burada \mathbf{I}_M tüm elemanları $1/M$ olan $M \times M$ boyutlu bir matristir. $\tilde{\boldsymbol{\Sigma}}_X^K$ matrisinin en büyük l özdeğerine $(\lambda_1^K, \lambda_2^K, \dots, \lambda_l^K)$ karşılık özvektörler $(\boldsymbol{\theta}_1^K, \boldsymbol{\theta}_2^K, \dots, \boldsymbol{\theta}_l^K)$ seçilir. Hedefin eğitim örnekleri için test vektörü \mathbf{z} ’nin i . özniteliği Eşitlik 4.9 ile bulunur.

$$f_i = (1/\sqrt{\lambda_i^K}) \boldsymbol{\theta}_i^{K\top} [k(\mathbf{x}_1, \mathbf{z}), k(\mathbf{x}_2, \mathbf{z}), \dots, k(\mathbf{x}_M, \mathbf{z})], \quad i = 1, \dots, l \quad (4.9)$$

Algoritma 1 ÇFKD ile Boyut Azaltma

Giriş: N adet örnekten, $\mathbf{x}_i \in \mathbb{R}^d$, oluşan veri ve her gruba (pozitif ve negatif) ait M adet eğitim örneği.

- 1: Bir çekirdek fonksiyonu ve varsa parametresi seç, ardından Eşitlik 3.11’de verilen $\boldsymbol{\Sigma}_X^K$ ve $\boldsymbol{\Sigma}_Y^K$ çekirdek matrislerini hesapla. Eşitlik 3.13’ü kullanarak $\tilde{\boldsymbol{\Sigma}}_X^K$ matrisini merkezileştir.
- 2: $\tilde{\boldsymbol{\Sigma}}_X^K$ matrisini öz ayrıştırmaya tabi tut, özvektörlerini, $\boldsymbol{\theta}_i^K$, ve özdeğerlerini, λ_i^K , bul. Baskın özvektörlerin oluşturduğu alt uzay hedef sınıfı daha iyi temsil edecektir.
- 3: Verilen tüm $\mathbf{z}_i \in \mathbb{R}^d$ vektörleri için Eşitlik 4.9’u kullanarak öznitelik vektörünü bul. Böylece, indirgenmiş öznitelikler elde edilmiş olacak.


Çıkış: İndirgenmiş veri $\mathbf{F} = \{\mathbf{f}_1, \mathbf{f}_2, \dots, \mathbf{f}_N\}$, $\mathbf{f}_i \in \mathbb{R}^l$.

θ_i^K , Σ_X^K matrisinin λ_i^K özdeğerine karşılık gelen özvektörüdür. Bu işlemlerin ardından çıkarılan öznitelikler $\mathbf{f} = [f_1, f_2, \dots, f_l]$ vektöründe toplanır. Böylece $\mathbf{z} \in \mathbb{R}^d$ orijinal vektörü için l -boyutlu, $l < d$, yeni bir dönüştürülmüş vektör elde edilir. Bu işlem tüm test örnekleri üzerinde uygulanırsa, verinin hedef sınıf öznitelik korunduğu indirgenmiş bir hali elde edilecektir. Önerilen ÇFKD-tabanlı boyut azaltma algoritmasının adımları Algoritma 1 ile özetlenmiştir.

4.4 Deneysel Sonuçlar

Sunulan yöntemlerin performanslarını değerlendirmek için iki gerçek hiperspektral veri kullanılmıştır. İlki, SPECIM tarafından üretilen algılayıcı ile 7 Haziran 2015’de Çatalca’dan (İstanbul) alınmış sahnedir. Görüntü orijinalinde 810×1091 piksel ve spektrumun görünür-yakın bölge kızılötesi bölgesinde 196 spektral banttandır. 36 bant gürültüden dolayı çıkarılmıştır. Bu bölümde bahsedilen yöntemler test edilirken orijinal sahnenin 140×100 boyutlu iki alt görüntüsü kullanılmıştır. İki insan yapımı aracı (V_1 ve V_2) içeren bu eğitim ve test görüntüleri Şekil 4.2’de verilmiştir. Sahte renkli görüntüler {R:85, G:52, B:19} nolu bantlar kullanılarak elde edilmiştir.


Reflective optics system imaging spectrometer (ROSIS-03) [68] hava aracı algılayıcısı ile Pavia Üniversitesi (Pavia, İtalya) üzerinde kaydedilmiş görüntü [69] ikinci veri kümesi olarak seçilmiştir. Görüntü orijinalinde 610×340 piksel ve $0.43-0.86 \mu\text{m}$ dalga boyu aralığında 115 spektral banttandır. 12 bant gürültüden dolayı çıkarılmış ve böylece kalan 103 bant deneylerde kullanılmıştır. Yöntemler orijinal sahnenin 200×150 boyutlu iki alt görüntüsü üzerinde uygulanmıştır. İki insan yapımı materyal (asfalt



(a)

(b)

Şekil 4.2 Çatalca verisinin alt sahneleri: (a) V_1 hedefini içeren eğitim görüntüsü (b) V_2 hedefini içeren test görüntüsü



(a)

(b)

(c)

(d)

Şekil 4.3 Pavia Üniversite verisinin alt sahneleri: (a) Eğitim görüntüsü (b) Eğitim görüntüsünün asfalt (*asphalt*) ve tuğlalar (*bricks*) içeren doğrulama haritası (c) Test görüntüsü (d) Test görüntüsü asfalt ve tuğlalar içeren doğrulama haritası




ve tuğlalar) hedef olarak seçilmiştir. Pavia üniversite verisinin üç bantlı renklendirilmiş (R:85, G:52, B:19) eğitim ve test alt görüntüleri ve bunlara karşılık gelen doğrulama verileri Şekil 4.3’de verilmiştir.

Her bir hedef için eğitim ve test örneklerinin sayısı Çizelge 4.1’de verilmiştir.

Çizelge 4.1 Boyut azaltma için kullanılan hedef sınıf eğitim ve test örnekleri sayısı

Veri	Hedef	Eğitim Örnekleri Sayısı	Test Örnekleri Sayısı
Çatalca	V ₁	157	–
	V ₂	–	273
Pavia Üniversite	Asfalt	147	851
	Tuğla	135	1876


Yöntemlerin karşılaştırması sınıflama doğruluğu, geri getirme oranı ve Kappa katsayısı [30] üzerinden yapılmıştır. Çalışmada, ÇFKD oluşturulurken çekirdek fonksiyonu olarak RTF seçilmiştir. RTF’nin bağımsız değişkeni σ her bir hedef için belirli bir aralıkta aranmıştır. Her bir hedef için Çizelge 4.1’de verilen eğitim örnekleri sayısının üçte biri kullanılarak normalize edilmiş veriler üzerinde parametre araması gerçekleştirilmiştir. Bu kısımda, ÇFKD özdeğerleri seçilirken toplamsal bilginin %95’inin korunacağı varsayılmıştır. Yani, özdeğerler büyükten küçüğe sıralanıp toplamsal yüzdeleri hesaplanmış ve bu değer 95’e ulaştığında özdeğer seçimi durdurulmuştur. Her bir hedef



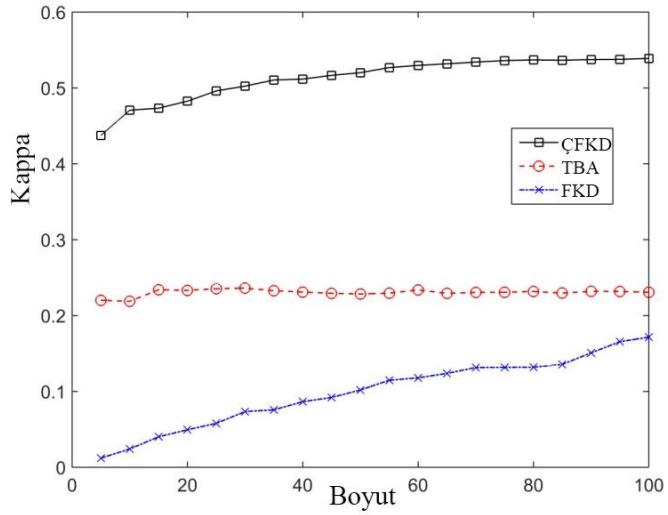

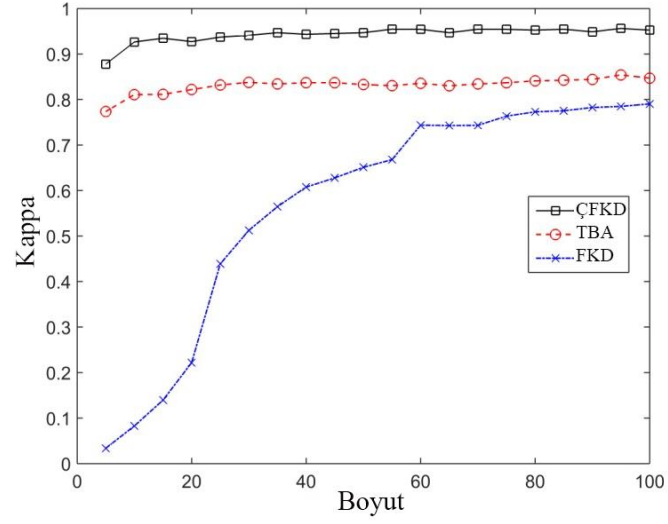
Şekil 4.4 V_2 (üstte), asfalt (ortada), ve tuğla (altta) için sigma değerlerine karşılık üretilen Kappa katsayıları

için, çekirdek parametresinin $[0.1 - 2]$ aralığında 0.02 adımlarla üretilen Kappa değeri Şekil 4.4'de gösterilmiştir. Boyut indirgenmiş veriler üzerinde sınıflandırma doğrusal ayırma analizi (DAA) ile gerçekleştirilmiştir. V_2 , asfalt ve tuğla hedefleri için optimum parametre değeri sırasıyla 0.62, 0.23 ve 0.18 olarak bulunmuştur.

Çatalca test görüntüsü için her bir yöntemle üretilen ilk üç baskın bileşen Şekil 4.5'te verilmiştir. FKD ve ÇFKD Çizelge 4.1'de belirtilen sayıda eğitim örneği alınarak uygulanmıştır.



Şekil 4.5 Farklı yöntemlerle üretilen baskın bileşenler. İlk satır: Çatalca test görüntüsünün sırasıyla 450.34, 550.09 ve 651.85 nm dalga boylarına karşılık gelen orijinal üç bandı. İkinci satır: en baskın ilk üç temel bileşen. Üçüncü satır: en çok bilgi içeren ilk üç FKD bileşeni. Dördüncü satır: en baskın ÇFKD bileşenleri



Şekil 4.6 Farklı boyutlara karşı üretilen Kappa katsayıları: V_2 (üstte), asfalt (ortada) ve tuğla (altta)

TBA, FKD ve ÇFKD yöntemlerinin karşılaştırmalı analizinde, boyut indirgeme performansı 10-katlı çapraz-doğrulama stratejisinin uygulandığı DAA ile test edilmiştir. Sayısal olarak ilk karşılaştırmada değişen boyut sayılarında üretilen Kappa katsayıları kaydedilmiştir. Verinin her bir yöntem için yeni boyutu belirli bir aralıkta değiştirilmiş ve bu boyutlarda her bir hedef için sınıflandırma gerçekleştirilmiştir. Pavia verisi test edilirken hedefin biri sınıflandırma aşamasına girerken diğer hedef arka plana dâhil edilmektedir. Bu deneye ait sonuçlar Şekil 4.6’da sunulmuştur. Şekil 4.6 açıkça göstermektedir ki ÇFKD her bir hedef için aynı boyut sayılarında karşılaştırıldığı diğer yöntemlere göre hedef sınıf için daha iyi bir ayırma sağlamaktadır.

Çizelge 4.2 Farklı yöntemlerle üretilen Doğruluk (%), Geri getirme (%) ve Kappa, κ , değerleri.

Veri	Hedef	Öznitelik Çıkarımı	Öznitelik Sayısı	Doğruluk	Geri Getirme	κ
Çatalca	V ₂	Ham	160	99.38	99.41	0.8568
		TBA	16	99.21	99.26	0.8218
		FKD	94	99.23	99.27	0.8269
		ÇFKD	71	99.80	99.93	0.9469
Pavia Üniversite	Asfalt	Ham	103	76.40	76.02	0.1328
		TBA	3	73.34	72.58	0.1294
		FKD	85	70.18	70.08	0.0747
		ÇFKD	66	96.70	96.97	0.5859
	Tuğla	Ham	103	75.55	74.73	0.2308
		TBA	3	69.40	67.41	0.2033
		FKD	85	67.52	67.57	0.1103
		ÇFKD	80	91.88	92.29	0.5295

Son deneyde ise yöntemlerin dönüşümü tamamladığı yeni uzayların boyutu toplamsal değişiminin %99’unun korunduğu değer olarak alınmıştır. Örneğin bu ölçüte göre Çatalca verisinin yeni boyutu TBA, FKD ve ÇFKD için sırasıyla 16, 94 ve 71 olmuştur. Test

verisinin orijinal özniteliklerinin (ham spektral bantların tümü) kullanıldığı sınıflandırma testinin sonuçları da üretilmiştir. Bu deneyin ayrıntılı sonuçları Çizelge 4.2’de verilmiştir. Çizelge 4.2’de her bir hedef için en iyi skor koyu olarak vurgulanmıştır. V_2 sonuçlarına bakıldığında, FKD’nin TBA’dan daha faydalı öznitelikler ürettiği görülecektir. Bununla birlikte, TBA FKD’ye göre diğer hedeflerde daha iyi performans göstermiştir. Tüm sonuçlar değerlendirildiğinde, önerilen ÇFKD tabanlı yaklaşımın tüm hedeflerde tüm metrikler cinsinden daha üstün olduğu söylenebilir.



TEK-SINIFLI FUKUNAGA-KOONTZ DÖNÜŞÜMÜ ALGORİTMALARI

Bu bölümde, tek-sınıflı sınıflandırma probleminin çözümü için FKD yönteminin kullanılabilirliği incelenmiştir. Yalnız pozitif (hedef) sınıf eğitim örneklerinin istatistiksel özellikleri kullanılarak oluşturulan yapay negatif (hedef-olmayan) eğitim sınıfından, FKD yönteminin eğitilmesinde faydalanılmıştır. Geliştirilen yöntemin [tek-sınıflı FKD, TS-FKD] çekirdek versiyonu (TS-ÇFKD), çoklu-çekirdek versiyonu (TS-ÇÇFKD) ve seçici çoklu-çekirdek versiyonu (TS-SÇÇFKD) da bu bölümde tanıtılmıştır. Geliştirilen yöntemler iki-sınıflı verilerde sınıflandırma deneyleri ile test edilmiştir. Bunun yanında, eğitimci hedef tespiti de bir tek-sınıflı sınıflandırma problemi olarak düşünülerek, hiperspektral görüntülerde hedef tespiti görevi için TS-FKD yönteminin uygulanması önerilmiştir.

5.1 Tek-sınıflı Fukunaga-Koontz Dönüşümü

FKD yöntemini tek-sınıflı çalışır hale getirmek için, bir eğitim kümesine ait vektörlerin alt ve üst sınırlarının oluşturduğu zarf yüzeyinin dikkate alınması planlanmıştır. Bu zarfın sınırlarını belirlediği bölge, Demirci vd. [70] tarafından gerçekleştirilen çalışmada vektör tüneli olarak adlandırılmıştır. Söz konusu çalışmada, hiperspektral hedef tespiti test vektörünün bu zarfa olan uzaklığı dikkate alınarak gerçekleştirilmiştir. Bu tez kapsamında, [70] çalışmasından ilham alınarak oluşturulan zarfın dışında (üzerinde ve/veya altında) yine eğitim örneklerinin istatistikleri kullanılarak bir yapay hedef-olmayan vektör kümesi oluşturulmaktadır. Oluşturulan yapay vektör grubu, FKD yönteminde negatif ya da hedef-olmayan sınıf olarak tanımlanan grubun yerini almaktadır. Yöntemin özgün olan unsuru burada ortaya çıkmaktadır. Böylece, yalnız hedef sınıf eğitim örnekleri kullanılarak FKD yönteminin çalışması ve hedef sınıfa ait test

örneklerinin söz konusu yöntem tarafından tahmin edilmesi gerçekleştirilmiş olacaktır. Bu nokta yöntemin en önemli avantajıdır.

FKD yönteminin girişine uygulanacak yapay negatif sınıf örneklerinin oluşturulması için önerilen yöntem aşağıdaki adımları içermektedir. Pozitif sınıf için bir eğitim vektör kümesi $\{\mathbf{x}_i\}_{i=1}^m \in \mathbb{R}^d$ ile verilsin. Burada, d verinin boyutu olmak üzere her \mathbf{x}_i d -boyutlu bir vektörü temsil etmektedir, $\mathbf{x}_i = (x_{i1}, \dots, x_{id})$. FKD yöntemi anlatılırken belirtildiği gibi, pozitif ve negatif sınıflara ait kovaryans matrisleri seçilen örnek sayısından bağımsız olarak $d \times d$ olacaktır. Gösterimin sadeliği açısından yapay negatif sınıf eğitim örneği sayısını da m olarak alalım. Pozitif sınıf örneklerinin oluşturduğu vektör zarfının üzerinde kalan m_1 adet örnek

$$\mathbf{y}_{uk} = \max(x_{ik}) + (p \times \text{std}(x_{ik})) \quad u = 1, \dots, m_1 \quad (5.1)$$

eşitliği ile oluşturulur. Pozitif sınıf örneklerinin oluşturduğu vektör zarfının altında kalan m_2 adet örnek ise


$$\mathbf{y}_{vk} = \min(x_{ik}) - (p \times \text{std}(x_{ik})) \quad v = 1, \dots, m_2 \quad (5.2)$$

formülü yardımıyla bulunabilir. Eşitlik 5.1 ve 5.2'de, \max , \min ve std işlevleri sırasıyla maksimum değer, minimum değer ve standart sapma değeri hesaplayan operatörleri ve p sınıf-içi çeşitliliği artıran kullanıcı tarafından belirlenecek bir katsayıyı temsil etmektedir. Yapılan deneyler, bu katsayının $p(a)$ ile gösterilmesinin ve 1 ile a arasında rasgele bir tamsayı değeri atayan fonksiyon şeklinde tanımlanmasının uygun olacağını göstermiştir. Pozitif sınıf eğitim grubu ile eşit sayıda yapay örnek oluşturulduğu dikkate alınırsa, $m_1 + m_2 = m$ yazılabilir.

Bu adımlar sonucu, sözde hedef-olmayan eğitim vektörleri matrisi $\mathbf{Y} = [\mathbf{y}_{uk}, \mathbf{y}_{vk}]$ ($u = 1, \dots, m_1$ ve $v = 1, \dots, m_2$) oluşturulmuş olacaktır. Önerilen yaklaşım bu aşamadan sonra esasında FKD ve ÇFKD temel yöntemlerine göre ayrılmaktadır. TS-FKD, \mathbf{X} ve \mathbf{Y} ortalananmış giriş kümelerinin kovaryans matrislerinin ($\mathbf{\Sigma}_X = \mathbf{X}\mathbf{X}^T$ ve $\mathbf{\Sigma}_Y = \mathbf{Y}\mathbf{Y}^T$) toplamının özdeğer-özvektör ayrıştırması ile devam etmektedir.

Eşitlik 5.1 ve 5.2'de yer alan katsayının, p , örüntü ayırt ediciliği üzerindeki etkisini incelemek için UCI makine öğrenmesi veri havuzundan alınmış *iyonosfer* verisi ile deneyler gerçekleştirilmiştir. Klasik FKD girişine uygulanacak eğitim kümesi için pozitif ve negatif sınıfın %20'si seçilmiştir. TS-FKD için ise negatif örnekler Eşitlik 5.1 ve 5.2

ile oluşturulmuştur. Şekil 3.1’de temsilen verilen ayırt edici alt uzaylar, TS-FKD için, $p(a)$ ’da yer alan a değerinin 3 farklı değeri, $\{2,5,10\}$ ile ayrı ayrı çizdirilmiştir. FKD alt uzayının da karşılaştırma amaçlı çizdirilmesi ile oluşan dört eğri Şekil 5.1’de gösterilmiştir. Bu karşılaştırma deneyi, katsayının hassas ayarlanması ile klasik modele yakın alt uzaylar elde edilebileceği sonucunu çıkarmıştır.



Şekil 5.1 FKD ve üç farklı katsayı için TS-FKD'nin ayırt edici alt uzayları

5.2 Tek-sınıflı Çekirdek Fukunaga-Koontz Dönüşümü

Bir önceki kısımda, TS-FKD yaklaşımının oluşumu sunulmuştur. Tıpkı FKD yönteminde olduğu gibi, ele alınan probleme ait verideki doğrusal olmayan öznitelikleri keşfetmek için TS-FKD yöntemi çekirdek versiyonuna (TS-ÇFKD) dönüştürülebilir. Pozitif sınıfa ait ve önerilen yöntemle hesaplanmış negatif sınıfa ait giriş verilerinden, herhangi bir çekirdek fonksiyonu yardımıyla hesaplanmış çekirdek matrisleri (Σ_X^K ve Σ_Y^K) toplanır ve toplam matrisinin özayırıştırması gerçekleştirilir. TS-ÇFKD algoritmasının devamı klasik

ÇFKD gibi sürdürülür. Bunun yanında, tek bir çekirdekle işlemlerin sürdürüldüğü ve bu çekirdeğin de ayarlanması gereken bir parametresi olduğu düşünülürse, TS-ÇFKD için kullanıcı tarafından belirlenmesi ya da ayarlanması gereken temel girişler; katsayı yerine geçecek fonksiyon parametresi $p(a)$, çekirdek fonksiyonu ve çekirdek fonksiyonu parametresidir.

Elbette, doğrusal olmayan dönüşüm esnasında kullanılan çekirdek sayısına göre algoritmalar çeşitlenecektir. İlerleyen kısımlarda, topluluk öğrenme (TÖ) yaklaşımı ile bir ÇÇÖ yönteminin TS-ÇFKD'ye eklenmesi üzerinde durulmuştur. Geliştirilen yaklaşım, tek-sınıflı çoklu-çekirdek FKD (TS-ÇÇFKD), aday çekirdeklerin ağırlıklarını belirlerken, onların örüntüleri ayırt etme kapasitelerini dikkate almaktadır. Son olarak, zayıf çekirdeklerin kümeleme yöntemi ile elendiği ve yalnız geriye kalanların TS-ÇÇFKD oluşumunda kullanıldığı bir seçici ÇÇÖ stratejisi tanıtılmıştır.

5.3 Topluluk Öğrenme Yaklaşımı ile Tek-sınıflı Çoklu-çekirdek FKD

ÇÇÖ, tek bir çekirdek yerine birden çok çekirdeğin birleştirilmesine odaklanan bir tekniktir. TÖ ise iyileştirilmiş bir sınıflandırma sonucu için temel (zayıf) sınıflandırıcıların bir birleşimini oluşturan diğer bir yaklaşımdır. Bölüm 3.2.3'de de ortaya konulduğu gibi, TÖ metodolojisi içindeki zayıf sınıflandırıcılar çekirdek kaynaklı sınıflandırıcılar olarak düşünülürse, bu iki yöntem aynı amacı güder hale gelecektir.

İyileştirilmiş bir ayırma/sınıflandırma performansı için, önerilen TS-FKD yaklaşımı TÖ stratejileri ile tek-sınıflı çoklu-çekirdek FKD (TS-ÇÇFKD) hale getirilmiştir. Klasik bir TÖ yaklaşımında, alt sınıflandırıcıların bir test örneği üzerindeki kararları birleştirilirken her bir alt sınıflandırıcının ağırlığının (sınıflandırma yeteneğinin bir ölçüsü gibi düşünülebilir) belirlenmesi gerçekleştirilir. Ağırlıksız bir doğrusal birleşimin uygulandığı durumlara, Bölüm 3.2.3'de de belirtildiği gibi ağırlıksız oylama yöntemi denilmektedir. TÖ teorisinde, iyileştirilmiş ve etkili bir sınıflandırma sonucu elde etmek için göz önünde bulundurulması gereken iki faktör bulunmaktadır ki bunlar; tekil sınıflandırıcıların ayırma/sınıflandırma yeteneği ve sınıflandırıcılar arasındaki çeşitliliktir [71], [72]. Yüksek ayırma yeteneği ve daha büyük çeşitlilik, daha iyi bir performans üretilmesini sağlayacaktır. ÇÇÖ'de ayırma yeteneği, çekirdek kaynaklı sınıflandırıcıların yeteneğine, dolayısıyla seçilen çekirdek ve varsa parametresinin örüntüleri ayırmada ne kadar katkı sağladığına bağlıdır. Buradan hareketle, bu TÖ stratejisinden ilham alınarak ve TS-ÇFKD

yaklaşımı temel sınıflandırıcı seçilerek, farklı çekirdeklerle oluşturulmuş her bir TS-ÇFKD sınıflandırıcısının sınıflandırma yeteneği nicel olarak ölçülmüş ve bu ölçümler ağırlık olarak değerlendirilip nihayetinde TS-ÇÇFKD algoritması oluşturulmuştur.

Alt-çekirdeklerin ayırma yeteneklerini sayısal olarak hesaplamak için, iki-sınıflı verilerin ÇFKD ve TS-ÇFKD tarafından üretilmiş ayırt edici alt uzayları analiz edilmiştir. Yapılan analizlere ve [48] ile verilen çalışmada yer alan çıkarımlara dayanarak, FKD ile üretilen tamamlayıcı özdeğerlerin oranının, λ_p/λ_n , ayırt ediciliğin bir ölçütü olarak kullanılabilceği anlaşılmıştır. Şekil 3.1 dikkate alınarak, A_1 , A_2 ve A_3 bölgelerinin azalan sırada en ayırt edici bölgeler olduğu söylenebilir. Çünkü bu bölgelerde özdeğerlerin oranı sırasıyla sonsuz, sonlu (sonsuzdan küçük) ve sıfır değerindedir. A_4 bölgesi kullanışlı bir bilgi içermediğinden ihmal edilebilir. Deneylelerden ayrıca iki önemli gözlem daha not edilmiştir ki bunlar; 1) eşit özdeğerlerin, $\lambda_p = \lambda_n = 0.5$, sayısının artması ve 2) bir FKD alt uzayında λ_p/λ_n oranlarının maksimum ve minimum değerlerinin birbirlerine oranının artması sınıflandırma performansını düşürmektedir. Bu çıkarımlardan hareketle, TS-ÇFKD için bir alt-çekirdek ağırlıklandırma yöntemi önerilmiştir (Algoritma 1). Elbette, önerilen yöntem klasik iki-sınıflı ÇFKD için de uygulanabilir niteliktedir.

Algoritma 1 Alt-çekirdek Ağırlıklarının Hesaplanması

Giriş: TS-ÇFKD’de her bir aday çekirdek, k_j , tarafından üretilen pozitif ve negatif örüntülerin özdeğer oranları kümesi:

- $S_j = \{\lambda_p^i/\lambda_n^i\}; i = 1, \dots, D$

1: **if** $((S_j \cong 1) \text{ durumuna uyan oran sayısı})/D > 0.1$

2: $w_j = 0$

3: **else**

4: $w_j = \frac{\min(S_j)/\max(S_j)}{Z}$

Z , ağırlıkları bir dağılım haline getiren normalizasyon faktörüdür.

5: **end**

Çıkış: Ağırlıklar, w_j .

Yukarıda verilen algoritma kullanılarak, her bir alt-çekirdeğin ağırlığı, eğitim verisi üzerindeki ayırma performansına göre elde edilir. Bu ağırlıklar, TS-ÇÇFKD algoritmasında test verisi üzerindeki tahminlere skor olarak doğrudan uygulanır. Çeşitlilik için ise, aday çekirdeklerin eğitim verisi üzerindeki tahminleri incelenmiştir.

Herhangi iki çekirdek, eğitim grubunun tümü için aynı sonucu üretiyorsa, bunlardan biri çeşitliliği artırmak için atılmıştır.

5.4 Tek-sınıflı Seçici ÇÇFKD

Aday çekirdeklerin ağırlıklarının belirlenmesinin ardından, sınıflandırmadan önce tek-sınıflı seçici ÇÇFKD (TS-SÇÇFKD) yönteminin zayıf çekirdekleri elemesi gerekmektedir. Önceden belirlenmiş bir eşik değerinin üzerinde kalan ağırlıkları üreten çekirdeklerin güçlü olarak etiketlenip seçilmesi ya da yine önceden belirlenmiş sayıda en yüksek skoru üreten çekirdeklerin alınması muhtemelen en basit yaklaşımlardır. Burada, çekirdek seçimi için kullanıcı tarafından belirlenecek güçlü çekirdek sayısı, çeşitliliği artırmak için elenen çekirdekler dikkate alınarak belirlenmelidir.

Tez kapsamında, TS-SÇÇFKD için önerilen yaklaşım, aday çekirdekleri gruplandırmak için popüler bir kümeleme tekniği olan k -ortalama yönteminin kullanılmasıdır. Bu yaklaşımda, Öklid uzaklığı kullanılarak, aday çekirdeklerin işlem sonunda güçlüler ve zayıflar olarak etiketleneceği iki farklı kümede toplanması gerçekleştirilmektedir.

5.5 Deneysel Sonuçlar

Bu kısımda öncelikle, önerilen TS-FKD algoritmalarının performansı iki-sınıflı veriler üzerinde test edilmiştir. Testler için UCI makine öğrenmesi veri havuzundan seçilmiş üç adet düşük boyutlu, iki adet de yüksek boyutlu veri kullanılmıştır. Sınıflandırmadan önce tüm veriler normalize edilmiştir. Kullanılan veriler hakkında özet bilgi Çizelge 5.1’de verilmiştir. Bu kısımda, sınıflandırma doğruluğu performans değerlendirme metriği olarak kullanılmıştır.

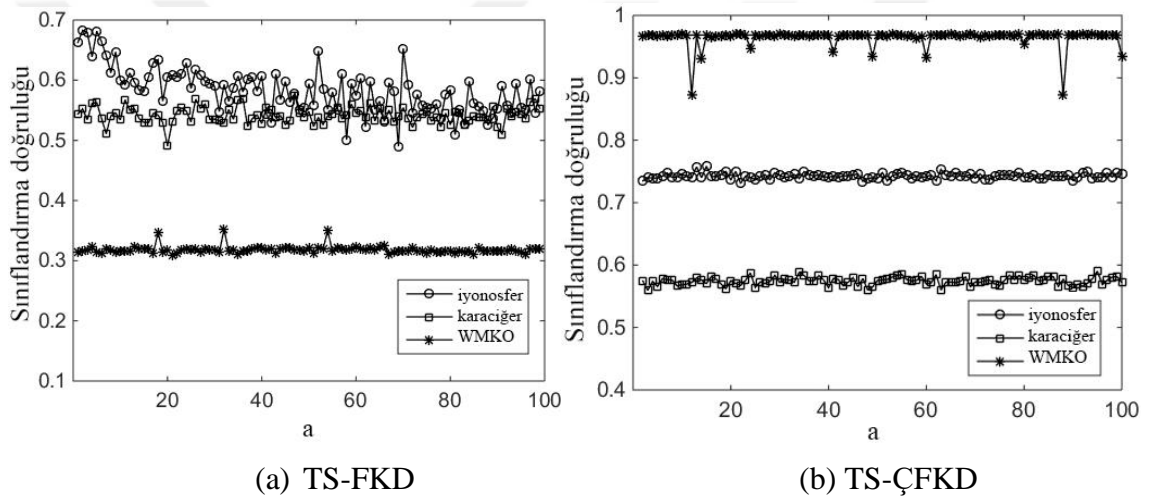
Çizelge 5.1 Kullanılan veri kümeleri

Tür	Veri	Örnek Sayısı	Eğitim Örnekleri Yüzdesi	Sınıf Sayısı	Öznitelik Sayısı
Düşük boyutlu	Deri	245057	0.1	2	3
	Karaciğer	345	10	2	6
	WMKO	683	10	2	9
Yüksek boyutlu	İyonosfer	351	10	2	33
	Sonar	208	10	2	59

Öncelikle, Eşitlik 5.1 ve 5.2’de yer alan p parametresinin önerilen yöntem üzerindeki etkisi incelenmiştir. Bu amaçla, veri kümesinden seçilmiş bazı veriler (*iyonosfer*, *WMKO*, *karaciğer*) üzerinde TS-FKD ve TS-ÇFKD yöntemleri farklı katsayı değerleri ile test edilmiştir. TS-ÇFKD için RTF fonksiyonu çekirdek olarak seçilmiş ve ölçek parametresi:

$$\sigma = \sqrt{\sum_N \|x_k - \bar{x}\|^2 / N} \quad (5.3)$$

ile hesaplanmıştır. Eşitlik 5.3’de \bar{x} mevcut N adet eğitim örneğinin ortalamasıdır [73], [74]. Tüm veriler için, pozitif sınıf örneklerinin rasgele %10’u eğitim için seçilmiş ve bu işlem 10 kere tekrar edilmiştir. $p(a)$ fonksiyonunda a değeri [2-100] aralığında değiştirilmiş ve her bir değer için 10 kere tekrar eden koşurmaların ortalama sınıflandırma doğruluğu kaydedilmiştir. Bu deneyin sonuçları Şekil 5.2’de verilmiştir.

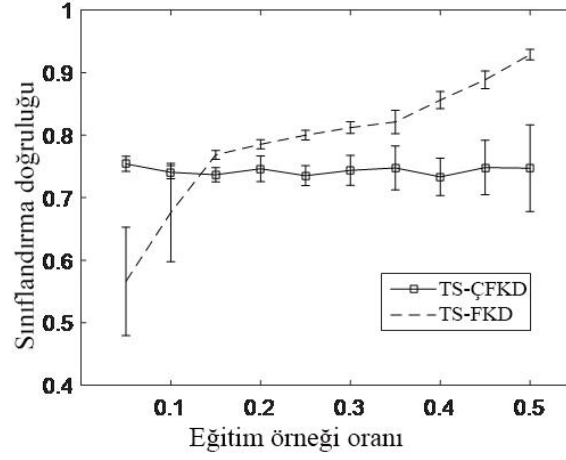


Şekil 5.2 TS-FKD ve TS-ÇFKD sınıflandırma doğruluğunun seçilmiş sınıflar üzerinde parametre değerine (a) göre değişimi


Şekil 5.2’de verilen deney çıktıları göstermiştir ki *iyonosfer* verisi hariç değişen a değeri ile sınıflandırma doğruluğu arasında belirgin bir eğilim yoktur. TS-FKD için, küçük a değerleri *iyonosfer* verisinde daha iyi performans üretmişlerdir. Burada sezgisel olarak, ayırma/sınıflandırma doğruluğunun pozitif sınıfın temsil ediciliğine bağlı olduğu belirtilebilir. Başka bir ifadeyle, pozitif sınıf eğitim örneklerinin sınıf temsil ediciliği arttıkça, negatif sınıf eğitim örneklerinin ayırma/sınıflandırma üzerindeki etkisi azalmaktadır.

Önerilen doğrusal (TS-FKD) ve tek çekirdekli doğrusal olmayan (TS-ÇFKD) yöntemlerin performansının, eğitim kümesi boyutuyla ilişkisini ortaya koymak için yine önceki adımda verilen veri kümeleri üzerinde testler gerçekleştirilmiştir (Şekil 5.3). RTF

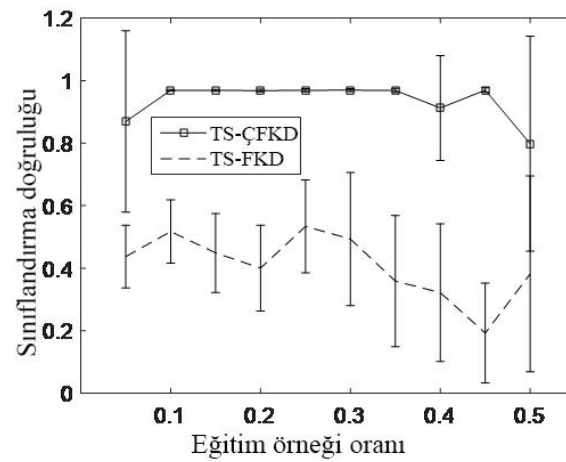
çekirdek yine Eşitlik 5.3 yardımıyla hesaplanan ölçek parametresi ile uygulanmıştır. Deneylerin bundan sonraki bölümünde, $p(a)$ fonksiyonunda a değeri 4 olarak atanmıştır.



(a) *iyonosfer*



(b) *WMKO*



(c) *Karaciğer*

Şekil 5.3 Sınıflandırma doğruluğunun (ortalama ve standart sapma) eğitim kümesi oranına göre değişimi

TS-ÇFKD sonuçlarına bakılırsa, tüm verilerde, eğitim örnekleri oranının sınıflandırma performansı üzerinde önemli bir etkisinin olmadığı görülecektir. WMKO verisi için aynı gözlem TS-FKD durumunda yapılabilir. Buna karşılık, *iyonosfer* verisi için eğitim örnekleri sayısının artışı TS-FKD ile sınıflandırma doğruluğunda da artışa; *karaciğer* için ise tersi duruma neden olmuştur.

Eğitim örnekleri kümesi boyutunun etkisine ek olarak, seçilen örneklerin tüm kümeye oranının görece küçük olduğu durumlarda, örneğin %5, her iki yöntemin de tüm veriler üzerindeki performansının genel olarak tatmin edici olduğu anlaşılmıştır. Bu gözlemler, önerilen yöntemlerin küçük örnek boyutu koşullarında uygulanmaya elverişli olduğunu göstermektedir. Deneylerin bundan sonraki kısmında, eğitim örnekleri oranı Çizelge 5.1'e göre seçilmiştir.

Önerilen TS-FKD ve TS-ÇFKD algoritmaları, iki popüler tek-sınıflı sınıflandırıcı, tek-sınıflı DVM (TS-DVM) [75] ve destek vektör veri tanımlama (DVVT) [76], ile karşılaştırılmıştır. TS-DVM ve DVVT sınıflandırıcılar LIBSVM araç kutusu [77] kullanılarak uygulanmıştır. Öncelikle, TS-FKD ile DVM ve DVVT sınıflandırıcıların doğrusal versiyonları test edilmiştir. Bu deneye ait, birbirinden bağımsız 10 koşturmanın sonucu sınıflandırma doğruluğu (ortalama \pm standart sapma) cinsinden Çizelge 5.2'de verilmiştir. Çizelge 5.2'de her bir veri için en iyi performans koyu olarak vurgulanmıştır.

Çizelge 5.2 Farklı doğrusal tek-sınıflı sınıflandırma yöntemlerinin sınıflandırma doğrulukları (%)

Veri	TS-FKD	TS-DVM (Doğrusal)	DVVT (Doğrusal)
Deri	92.68 \pm 00.75	68.52 \pm 01.87	73.59 \pm 03.81
Karaciğer	52.44 \pm 04.01	51.65 \pm 04.87	51.46 \pm 01.68
WMKO	47.31 \pm 10.49	34.69 \pm 03.58	64.96 \pm 06.58
İyonosfer	69.87 \pm 06.04	61.97 \pm 07.01	58.00 \pm 03.49
Sonar	49.36 \pm 04.22	43.46 \pm 03.62	54.63 \pm 04.07

Literatürde kabul görmüş iki tek-sınıflı sınıflandırma algoritması ile önerilen TS-FKD yönteminin karşılaştırılmasında, bazı verilerde (*deri*, *karaciğer*, *iyonosfer*) önerilen yöntemin üstün performans gösterdiği, diğer verilerde ise DVVT algoritmasına göre başarısız olduğu görülmüştür. TS-FKD'nin üstün başarı gösterdiği *deri* ve *iyonosfer* verilerinde diğer yöntemlere göre belirgin bir başarı farkı var iken, en yakın yöntemle

fark sırasıyla yüzde 19.09 ve 7.9, *karaciğer* verisinde bu fark düşük, yüzde 0.79, kalmıştır.

Yukarıda bahsedilen yöntemlerin doğrusal olmayan (çekirdek) versiyonlarının karşılaştırması Çizelge 5.3’de verilmiştir. Çekirdek üretimi aşamasında, Eşitlik 5.3 ile üretilen ölçek parametresine sahip RTF çekirdek kullanılmıştır.

Çizelge 5.3 Farklı doğrusal olmayan tek-sınıflı sınıflandırma yöntemlerinin sınıflandırma doğrulukları (%)

Veri	TS-ÇFKD	TS-DVM (RTF Çekirdek)	DVVT (RTF Çekirdek)
Deri	96.52 ± 01.37	75.69 ± 03.43	75.70 ± 03.46
Karaciğer	58.38 ± 01.48	56.32 ± 03.78	56.03 ± 02.82
WMKO	96.87 ± 00.21	65.21 ± 07.97	66.34 ± 08.78
İyonosfer	73.77 ± 01.34	55.67 ± 05.57	55.77 ± 05.54
Sonar	56.22 ± 04.68	54.63 ± 01.07	54.63 ± 01.07

Çizelge 5.3’den de görülebileceği gibi, tüm yöntemler arasında, TS-ÇFKD en iyi sonucu üretmiştir. Özellikle *deri*, *WMKO* ve *iyonosfer* verilerinde, önerilen yaklaşım diğer yöntemlere belirgin bir farkla, en iyi ikinci yöntemle farklar sırasıyla yüzde 20.82, 30.53 ve 18, üstün gelmiştir. Doğrusal yöntemlerin sonuçları da incelenirse, TS-ÇFKD ile TS-FKD yöntemine göre daha başarılı sonuçlar üretilmesinin yanında ortalama sınıflandırma doğruluğunun genel olarak daha kararlı olduğu da farkedilecektir. Örneğin kaba bir karşılaştırmayla, TS-FKD için tüm verilerin standart sapma değerlerinin yüzdesel olarak toplamı 25.51 iken TS-ÇFKD için 9.08 olmuştur. TS-DVM ile DVVT algoritmalarının arasındaki incelemede ise, literatürde de belirtildiği gibi, iki yöntemin neredeyse eşdeğer performansa sahip olduğu görülebilir. Bu sonuçlar, önerilen yaklaşımın literatürde mevcut popüler yöntemlerle sınıflandırma doğruluğu açısından kıyaslanabilir olduğunu ve dolayısıyla güçlü bir alternatif olarak değerlendirilebileceğini kanıtlar niteliktedir.

Bu kısım için son deney, ÇÇÖ ve seçici ÇÇÖ (SÇÇÖ) yaklaşımlarının TS-ÇFKD üzerindeki etkisinin incelenmesine yöneliktir. Her bir veri için 21 farklı ölçek parametresine $\{\dots, \sigma - 0.2, \sigma - 0.1, \sigma, \sigma + 0.1, \sigma + 0.2, \dots\}$ sahip RTF ve 6 farklı dereceye $\{1, \dots, 6\}$ sahip polinom çekirdek uygulanarak 27 alt-çekirdekli bir küme oluşturulmuştur. Polinom çekirdek, d derecesini göstermek üzere $k(\mathbf{x}_i, \mathbf{x}_j) = (\mathbf{x}_i^\top \mathbf{x}_j +$

1)^d ile tanımlanır. TS-ÇFKD durumunda alt-sınıflandırıcıların hepsi, TS-SÇÇFKD durumunda ise yalnız güçlü bir ayırt ediciliğe sahip olanlar kullanılmıştır.

Tek çekirdekli yöntemin, alt-çekirdek sayısı kadar üretilen sınıflandırma doğruluğunun ortalama ve standart sapma değeri ile ÇÇÖ algoritmalarının sınıflandırma doğrulukları karşılaştırılmıştır. Sonuçlar Çizelge 5.4’de verilmiştir.

Çizelge 5.4 Tekli ve çoklu çekirdek yöntemlerinin sınıflandırma doğrulukları (%)

Veri	TS-ÇFKD	TS-ÇÇFKD	TS-SÇÇFKD
Deri	92.28 ± 03.21	99.14	99.14
Karaciğer	55.00 ± 12.66	58.73	58.73
WMKO	94.36 ± 07.53	96.13	96.13
İyonosfer	75.24 ± 04.04	80.00	81.97
Sonar	50.84 ± 11.69	52.13	53.72

Öngörüldüğü gibi en kötü performans TS-ÇFKD tarafından üretilmiştir. Dahası, TS-SÇÇFKD performansı genel olarak TS-ÇÇFKD performansından iyi çıkmıştır. Bununla birlikte, gerçek dünya uygulamalarında hangi çoklu-çekirdek yaklaşımının etkili olacağı açık bir sorudur. Bu iki yaklaşım arasında, sınıflandırma doğruluğu ve zaman verimliliği açısından bir ödünleşim olduğu değerlendirilmektedir.

Deneysel sonuçların buradan önceki kısmında, önerilen yöntemlerin bazı iki-sınıflı veriler üzerinde incelenmesi ve literatürde yer alan iki tek-sınıflı ayırma algoritması ile karşılaştırılması üzerinde durulmuştu. Bu kez, TS-FKD ve TS-ÇFKD yöntemlerinin, çok-sınıflı bir gerçek hiperspektral veride eğiticili hedef tespiti probleminin çözümünde göstereceği performans araştırılmıştır. Önerilen yöntemlerin tespit sonucu klasik FKD ve ÇFKD ile karşılaştırılmıştır. Veri olarak, detayları önceki bölümlerde verilmiş olan HYDICE *DC Mall* hiperspektral görüntüsü kullanılmıştır.

Hedef tespiti deneyleri için *DC Mall* verisinden 7 adet doğal ve insan yapımı materyal seçilmiştir (Çizelge 5.5). İlk deneylerde, FKD’nin klasik ve önerilen versiyonu kullanılarak tüm sınıflar için birbirlerinden bağımsız olarak deneyler gerçekleştirilmiştir. Karşılaştırmalar geri getirme oranı-yanlış alarm oranı (GGO-YAO) eğrisi altında kalan alan (EAA) cinsinden elde edilmiştir. FKD için arka plan eğitim örnekleri, hedef sınıf eğitim örnekleri sayısı kadar olacak şekilde görüntü üzerinden her bir yinelemede rasgele alınmıştır.

Çizelge 5.5 DC Mall verisi sınıfları hakkında bilgi

Hedef	Örnek Sayısı	Hedefin Tüm Veriye Oranı
Grass	1928	0.49
Roads	416	0.11
Roofs	3834	0.97
Shadow	97	0.02
Trails	175	0.04
Trees	405	0.10
Water	1224	0.31

Deneylerde, TS-FKD parametresi $p(a)$ ve eğitim kümesi boyutu da incelenmiştir. İlk senaryoda, $a = 2$ ve eğitim örnekleri sayısı her bir sınıf için $\{5, 10, 15\}$ seçilerek üç farklı karşılaştırma yapılmıştır. Bu deneyin sonuçları Çizelge 5.6'da verilmiştir.

Küçük örnek boyutu durumu için gerçekleştirilen bu deneyde, önerilen TS-FKD yönteminin, eğitim örneği sayısının 5 ve 15 olduğu durumlarda 7 sınıftan 4'ünde, 10 olduğu durumda ise 5'inde klasik yöntemi geçtiği görülmüştür. Bu üstünlük, arka plan (negatif) eğitim örnekleri kullanılmaksızın elde edildiğinden, hedef tespiti problemi için daha da anlamlı hale gelecektir. İkinci senaryoda, $a = 10$ olduğu durumda yine aynı sayıda eğitim örnekleri ile karşılaştırmalı hedef tespiti performansları elde edilmiştir. Daha yüksek parametre değeri için Çizelge 5.7 ile verilen sonuçlar incelendiğinde, TS-FKD tekniğinin yine kıyaslanabilir ve hatta ortalama EAA cinsinden üstün sonuçlar

Çizelge 5.6 Hedeflerin doğrusal yöntemlerle EAA değerlerinin (%) 10 bağımsız koşuturma ortalaması ($a = 2$)

Eğitim Örneği Sayısı	5		10		15	
	FKD	TS-FKD	FKD	TS-FKD	FKD	TS-FKD
Grass	55.51	53.64	38.88	76.21	50.70	58.39
Roads	64.01	64.85	65.70	68.23	64.40	74.58
Roofs	64.83	74.82	77.92	84.35	58.89	42.61
Shadow	51.02	58.12	62.91	55.78	48.97	62.96
Trails	81.83	69.61	58.37	74.48	67.85	71.96
Trees	65.93	47.79	55.36	62.45	51.70	41.38
Water	20.67	36.33	27.57	47.21	38.55	33.51

ürettiği farkedilecektir. Daha net bir ifadeyle, eğitim örneği sayısının 5 ve 10 olduğu durumlarda 7 sınıfın 6'sında, 15 olduğu durumda ise 5'inde önerilen yaklaşım klasik yaklaşıma göre belirgin bir performans artışı göstermiştir. Bu sonuçlar da, önerilen yaklaşımın hedef tespiti için uygun ve küçük örnek boyutu durumlarında sınıflandırmaya elverişli olduğunu göstermiştir.

Çizelge 5.7 Hedeflerin doğrusal yöntemlerle EAA değerlerinin (%) 10 bağımsız koşturma ortalaması ($a = 10$)

Eğitim Örneği Sayısı	5		10		15	
	FKD	TS-FKD	FKD	TS-FKD	FKD	TS-FKD
Grass	61.54	63.69	42.82	63.46	49.97	44.39
Roads	61.45	67.51	60.25	63.98	71.55	51.42
Roofs	69.43	74.05	64.51	85.83	59.22	77.95
Shadow	46.14	53.70	64.24	50.74	51.19	58.49
Trails	50.12	63.64	43.91	56.40	48.85	78.06
Trees	39.55	38.40	35.98	48.37	44.11	51.10
Water	17.55	26.90	27.32	42.82	23.97	34.57

Deneylerin bundan sonrası klasik ÇFKD ile TS-ÇFKD yöntemlerinin farklı eğitim örnekleri sayısı durumunda karşılaştırılması üzerinedir. Bu amaçla yine $a = 2$ ve eğitim örnekleri sayısı her bir sınıf için {5, 10, 15} seçilerek üç farklı karşılaştırma yapılmıştır (Çizelge 5.8). ÇFKD ve TS-ÇFKD çekirdek parametresi Eşitlik 5.3 ile hesaplanmıştır.

Çizelge 5.8 Hedeflerin doğrusal olmayan yöntemlerle EAA değerlerinin (%) 10 bağımsız koşturma ortalaması ($a = 2$)

Eğitim Örneği Sayısı	5		10		15	
	ÇFKD	TS-ÇFKD	ÇFKD	TS-ÇFKD	ÇFKD	TS-ÇFKD
Grass	100	99.87	100	100	100	100
Roads	99.84	95.32	99.80	96.59	99.83	99.75
Roofs	97.78	97.73	96.03	96.09	98.44	98.38
Shadow	94.41	93.64	95.36	96.12	95.63	95.69
Trails	99.92	94.50	99.92	94.09	99.92	98.62
Trees	99.85	99.32	99.87	99.63	99.82	99.59
Water	99.63	99.18	99.73	99.82	99.78	99.89

Çizelge 5.9 Hedeflerin doğrusal olmayan yöntemlerle EAA değerlerinin (%) 10 bağımsız koşturma ortalaması ($\alpha = 10$)

Eğitim Örneği Sayısı	5		10		15	
	ÇFKD	TS-ÇFKD	ÇFKD	TS-ÇFKD	ÇFKD	TS-ÇFKD
Grass	100	98.79	100	99.98	100	99.97
Roads	99.74	94.86	99.85	99.71	99.84	98.94
Roofs	93.11	93.21	94.01	93.99	96.86	96.88
Shadow	95.35	95.63	95.09	96.09	95.50	96.44
Trails	99.92	95.94	99.92	98.22	99.92	98.10
Trees	99.87	97.77	99.79	99.48	99.94	99.84
Water	99.69	90.13	99.68	92.22	99.69	99.84

Sonuçlar incelendiğinde ilk farkedilen, beklenildiği gibi çekirdek yöntemlerin klasik yaklaşımlara olan üstünlüğüdür. Bunun dışında, doğrusal versiyondan farklı olarak TS-ÇFKD yönteminde yöntem parametresinin etkisinin daha az olduğu görülmüştür. ÇFKD ile TS-ÇFKD'nin EAA cinsinden karşılaştırmasında, performans değerlerinin genel olarak birbirine yakın olduğu görülmektedir. Tez kapsamında geliştirilen TS-ÇFKD yönteminin veri içinden daha az bilgi kullanmasına rağmen literatürdeki önceki haliyle neredeyse aynı sonuçları üretmesi, önerilen tekniğin etkinliğini ortaya koymaktadır. Ayrıca bu aşamada, TS-FKD ve TS-ÇFKD yöntemlerinin yalnız hedef sınıf bilgisinin erişilebilir olduğu durumlarda da kullanılabilecek olması önemli bir avantaj olarak belirtilmelidir.

SONUÇ VE ÖNERİLER

Bu tez çalışmasında, hiperspektral görüntülerde hedef tespiti, sınıflandırma ve boyut azaltma için Fukunaga-Koontz Dönüşümü (FKD) tabanlı algoritmaların geliştirilmesi üzerinde durulmuştur. Geliştirilen yöntemler ayrıca literatürde bilinen karşılaştırma veri kümeleri üzerinde de test edilmiştir.

FKD, iki-sınıflı yapısından dolayı sınıflandırma uygulamalarında kullanılmaya elverişlidir. Doğrusal karakterde olan bu yöntemin çekirdek-tabanlı öğrenme yaklaşımları ile doğrusal-olmayan (çekirdek FKD, ÇFKD) versiyonu da literatürde sunulmuş ve termal görüntülerde hedef tespiti gibi çalışmalarda uygulanmasıyla başarılı sonuçlar alınmıştır. Tez çalışmasının başlarında, FKD ve ÇFKD ile hiperspektral görüntülerde sınıflandırma deneyleri gerçekleştirilmiştir. Yöntemlerin, hiperspektral görüntüler üzerinde daha önce denenmemiş biçimde çok-sınıflı biçimde uygulanmasıyla küçük örnek boyutu durumunda dahi başarılı sonuçlar elde edilmiştir. Beklenildiği gibi, klasik FKD yaklaşımının ÇFKD yöntemine göre düşük performans gösterdiği deneylerde ÇFKD, literatürde sınıflandırma amacıyla sıklıkla tercih edilen destek vektör makineleri (DVM) yöntemine göre de üstün başarı göstermiştir. Örneğin, orijinal özneliklerin kullanıldığı durumda, her sınıftan 5 örneğin eğitim amaçlı seçildiği 9 sınıflı *Indian Pine* verisinde, DVM toplam %54.87 sınıflandırma doğruluğu üretirken, RTF çekirdeğin kullanıldığı ÇFKD %62.41 oranında doğru sınıflandırmıştır. ÇFKD üstünlüğü eğitim örneği sayısının artışıyla sürmüştür. 16 sınıflı *Indian Pine* verisinin kullanıldığı deneylerde, DVM yöntemi RTF çekirdeğin uygulandığı ÇFKD yaklaşımına göre sırasıyla yüzde 11.66, 11.16 ve 9.86 geride kalmıştır. Eğitim örneğinin artmasıyla DVM ile ÇFKD yaklaşımı arasında farkın azaldığı görülmektedir. Bu durum da, küçük örnek boyutu durumunda ÇFKD yaklaşımının daha avantajlı olduğu varsayımını doğrulamaktadır. *DC Mall* verisi ile gerçekleştirilen deneyler de benzer doğrultuda sonuçlar üretmiştir. RTF

çekirdek sonuçlarına bakılırsa, DVM ile ÇFKD yaklaşımlarının sınıflandırma kesinlikleri arasındaki fark eğitim kümesi boyutu arttıkça azalmaktadır. Her sınıftan rasgele 5 örneğin seçildiği durumda bu fark yüzde 11.32 iken, 50 örnek durumunda 3.72 olmuştur.

Literatürde farklı uygulamalarda tercih edilen 4 farklı çekirdek fonksiyonunun ÇFKD üzerinde ayrı ayrı kullanıldığı deneylerde, 9 sınıflı *Indian Pine* durumunda *laplace* tipi çekirdek genel olarak en iyi sonuçları üretirken, 16 sınıflı *Indian Pine* verisi durumunda *logaritmik* fonksiyonun gerisinde kalmıştır. *DC Mall* verisi için konuşmak gerekirse, aradaki fark az olmakla birlikte, RTF çekirdek ile *laplace* tipi çekirdek farklı eğitim örneği sayılarında birbirlerine üstünlük göstermişlerdir. Farklı tip çekirdeklerle gerçekleştirilen bu deneyler, belirli bir çekirdeğin diğerlerini domine edemediğini göstermektedir. Buradan hareketle, çekirdek-tabanlı öğrenme yaklaşımının tercih edildiği durumlarda, istenilen performansı elde edebilmek için çekirdek ve/veya çekirdek parametresi seçimi önemli bir problem olarak ortaya çıkmaktadır denilebilir. Bu çıkarım ile ilgili açılımlara ve yorumlara ileriki paragraflarda değinilecektir.

Tez kapsamında kullanılan FKD ve ÇFKD yöntemlerinin iki-sınıflı karaktere sahip olmalarından ve gıda güvenliğinin toplumsal tabanda giderek artan kaygılarından yola çıkarak bir gıda kontrolü uygulaması gerçekleştirilmiştir. Geliştirilen yöntem bilgisayarla görmeye dayanmakta ve kıyma etinin yağ içeriğinin tahmin edilmesi görevine bir iki-sınıflı ayırma problemi olarak yaklaşmaktadır. Kıyma eti hiperspektral test görüntüsünden bağımsız olarak alınmış saf et ve yağ parçalarından elde edilen spektral imzaların kütüphane olarak kullanıldığı uygulamada, gerçek et ve yağ bileşeni oranlarına yakın değerlerde tahminler üretilmiştir. Yüzde 37.50, 54.55 ve 64.29 oranlarında yağ içeriği bulunan 3 ayrı veri setinin kullanıldığı deneylerde, ÇFKD sırasıyla yüzde 39.21, 52.16 ve 63.53 oranlarını tahmin etmiştir. Bu deneyde, ÇFKD algoritması oluşturulurken tek bir çekirdek (RTF) tercih edilmiş ve çekirdek parametresi yine tez kapsamında önerilen bir yaklaşımla seçilmiştir. Ayrıca, kıyma etinin görüntüsü alınırken, kıymanın bileşenlerinin birbirlerini engellememesi amacıyla düzleştirildiği not edilmelidir. Bu deneyler, fiziksel karışımların bilgisayarla görme tabanlı analizinde FKD-tabanlı algoritmaların kullanılabilceğini göstermiştir.

ÇFKD algoritması oluşturulurken kullanıcı tarafından karar verilmesi gereken ve sistem performansını oldukça etkileyen konuların başında çekirdek ve varsa parametrelerinin seçimi gelmektedir. Bu durum, başta DVM olmak üzere diğer çekirdek-tabanlı öğrenme

yaklaşımlarının da ortak sorunudur. Tez kapsamında, bu konu üzerinde de durularak veriye uygun çekirdek ve parametrelerinin seçimi/uyarlanması üzerinde ÇFKD özelinde çalışmalar gerçekleştirilmiştir. Genel olarak literatürde çoklu-çekirdek öğrenmesi (ÇÇÖ) başlığı altında incelenen bu konu, bir çekirdek kümesi üzerinde verilen çekirdeklerin bir en uygun birleşiminin aranmasını kapsamaktadır. Çekirdeklerin doğrusal veya doğrusal olmayan birleşimlerinin arandığı durumlarda, her bir çekirdek fonksiyonuna, verilen örüntüdeki sınıf veya grupları ayırma yeteneğine bağlı olarak bir ağırlık katsayısı atanmaktadır. Bu ağırlıklandırma ve birleştirme işleminin çekirdek fonksiyonunun orijinal katkısını engelleme gibi bir dezavantajı vardır. Buradan hareketle, literatürde başka bir sınıflandırıcı üzerinde önerilen kompozisyonel çekirdek birleşimi yöntemi ÇFKD algoritmasına uyarlanmış ve böylece geliştirilen algoritma hiperspektral görüntülerde hedef tespiti ve sınıflandırılması amacıyla kullanılmıştır. Tekli RTF çekirdeğin uygulandığı klasik ÇFKD ve iki farklı parametreye sahip RTF çekirdeklerin uygulandığı kompozisyonel birleşim ÇFKD (KB-ÇFKD) algoritmalarının karşılaştırıldığı deneylerde, öncelikle *Indian Pine* verisi üzerinden seçilmiş ve ayırt edicilikleri görece güç olan üç sınıf üzerinde hedef-arka plan ayrımı testleri gerçekleştirilmiştir. Her iki yöntem için de çekirdek parametreleri, tez kapsamında geliştirilen çekirdek seçimi algoritması ile bulunmuştur. 10, 20 ve 30 eğitim örneklerinin kullanıldığı *soybean-no till* sınıfı için KB-ÇFKD ve ÇFKD yöntemlerinin geri getirme oranı-yanlış alarm oranı (GGO-YAO) eğrisi altında kalan alanların yüzdesel farkları sırasıyla 2.68, 1.23 ve 2.57 olmuştur. *Soybean-clean till* için ise bu farklar 4.04, 2.88 ve 2.05 olarak çıkmıştır. Bu deney, tek bir çekirdeğin kullanıldığı yaklaşıma göre, aynı çekirdek kullanılsa dahi farklı parametrelerle çoğullanmış çekirdeklerin kompozisyonel birleşiminin üstün olabileceğini göstermiştir. Burada, iki yerine daha çok ve farklı çekirdeklerin uygulanması ile daha ayrıntılı bir analiz yapılabileceği söylenmelidir. Bunun yanında, önerilen algoritmanın klasik ÇFKD ile birlikte kompozisyonda kullanılan çekirdeklerin bir doğrusal veya değil birleşimi ile de karşılaştırılması daha anlamlı sonuçlara ulaştıracaktır. HyMap verisi üzerinde insan-yapımı araçların tespit edilmesi amacıyla gerçekleştirilen deneyler de önerilen KB-ÇFKD yaklaşımının klasik yöntemle göre daha iyi bir tespit performansı üretmesiyle sonuçlanmıştır.

Çekirdek-tabanlı öğrenmede, farklı kaynaklardan alınan veriler yardımıyla oluşturulmuş çekirdek matrislerinin birlikte değerlendirilebilmesi için bileşik çekirdekler (BÇ) adı verilen bir yaklaşım önerilmiştir. Çekirdek-tabanlı öğrenme teoremlerinden yola çıkılarak

iki çekirdek matrisinin (fonksiyonunun) toplanmasının ya da bir doğrusal birleşiminin yine bir çekirdek matrisine (fonksiyonuna) karşılık geldiği söylenebilir. Buradan hareketle, veriye uyarlamalı çekirdeklerin öğrenilmesi amacıyla, hiperspektral görüntülerde uzamsal ve spektral bilginin bir arada kullanılmasına çalışılmıştır. ÇFKD algoritmasının oluşturulması sırasında üretilen çekirdek matrisi, kullanılan sınıfa ait uzamsal özniteliklerden (örneğin komşuluk bilgisi) ve spektral bantlardan çıkarılan özniteliklerden üretilen ayırık çekirdek matrislerinin toplamı şeklinde alınmıştır. Doğrudan toplamın yanında, matrislere atanan ağırlıkların toplamının 1 olduğu bir formda ağırlıklı toplam ile de denemeler gerçekleştirilmiştir. Literatürde spektral boyut için *cauchy* çekirdek, uzamsal boyut için ise RTF çekirdek daha çok önerildiğinden, bu çalışmada da bu çekirdekler ilgili öznitelikler için tercih edilmiştir. *Indian Pine* verisi üzerinde gerçekleştirilen iki-sınıflı sınıflandırma deneylerinde, yalnız spektral özniteliklerle üretilmiş çekirdek matrisinin kullanıldığı duruma göre BÇ yaklaşımının belirgin bir performans artışını sağlamadığı görülmüştür. Literatürde yine aynı veride DVM sınıflandırıcı ile gerçekleştirilen çalışmada ise, sınıflandırma doğruluğu açısından önemli bir gelişme sağlandığı vurgulanmıştır. Burada, *Indian Pine* verisinin bu alanda kaydedilmiş ve araştırmacıların erişimine açılmış en eski verilerden biri olduğunu söylemek gerekir. Dolayısıyla, verinin yer çözünürlüğünün görece düşük olması uzamsal bilginin kalitesini de etkilemektedir. Bu kısımda sonuçları yorumlanan deneylerde, spektral bilginin üzerinde belirgin bir artışın sağlanamamasının bir nedeninin de bu olduğu düşünülmektedir. Ayrıca, kullanılan çekirdek fonksiyonlarının toplamsal performans üzerindeki etkileri çeşitlenebilmektedir. Farklı çekirdek ikilileri ile geliştirilecek yöntemlerin farklı sonuçlar üretebileceği unutulmamalıdır.

Önceki kısımlarda üzerinde durulan sonuçlar, belirli bir uygulama için istenen performansın çekirdek ve varsa parametresine bağlı olarak değiştiğini anlatmaktadır. Bu problemin çözümü için literatürde birçok çalışma yapılmışsa da, ÇÇÖ başlığı üzerinde en çok durulan yaklaşımları kapsamaktadır. Tez kapsamında ÇÇÖ probleminin çözümüne bir topluluk öğrenme (TÖ) stratejisi ile yaklaşmıştır. Bu yaklaşım aynı zamanda, ÇÇÖ konusunun daha az çalışılmış kısmını oluşturmaktadır. TÖ yaklaşımında temel olarak, birden çok sınıflandırıcı ya da eğitim kümesinin belirli bir test örneği üzerindeki kararlarının birleştirilmesi ile daha gürbüz ve kararlı sonuçların elde edilmesi amaçlanmaktadır. Aynı sınıflandırıcının farklı çekirdek ve/veya çekirdek parametreleri ile üretilmiş versiyonlarının alt-sınıflandırıcı olarak alındığı bir formda TÖ ile ÇÇÖ

arasındaki benzerlikler ortaya çıkacaktır. Buradan hareketle, iki ayrı çekirdek ile (RTF ve küresel) birbirinden bağımsız gerçekleştirilen denemelerde, 21 ayrı çekirdek parametresi kullanılarak ÇFKD'nin temel sınıflandırıcı alındığı alt-sınıflandırıcılar oluşturulmuştur. İki-sınıflı UCI veri kümeleri üzerinde yapılan sınıflandırma testlerinde, RTF sonuçlarına göre, ağırlıksız oylama ile birleştirilen alt-sınıflandırıcıların performansı ortalama tekli sınıflandırıcıya göre iki sınıfta yüksek, diğer iki sınıfta ise denk ya da düşük çıkmıştır. Küresel çekirdek durumunda ise, ağırlıksız oylama bir sınıf dışında sınıflandırma doğruluğu ve Kappa katsayısı cinsinden performansı geliştirmiştir. Bunlarla birlikte, ağırlıklı oylama ile birleştirilen durumda, hem RTF hem de küresel çekirdek ile tüm sınıflarda verilen metrikler cinsinden sınıflandırma performansı artırılmıştır.

TÖ ile ÇÇÖ problemi çözümünde, diğer ÇÇÖ uygulamaları dışında dikkate alınması gereken durumlar da ortaya çıkacaktır. Örneğin klasik bir TÖ uygulamasında, istenen performans artışının sağlanabilmesi için alt-sınıflandırıcıların tekil performanslarının vasat bir sınıflandırma kadar olduğu varsayılmaktadır. Alt-sınıflandırıcıların az da olsa belirli bir kısmının tek başına yüksek performans göstermesi durumunda, topluluk halinde öğrenme ile bu performansın geçilebilmesi için en azından ağırlıksız oylamadan daha karmaşık karar mekanizmalarının geliştirilmesi gereklidir. Tezin ilgili kısmında gerçekleştirilen deneylerde de, ağırlıksız oylama ile bazı durumlarda alınan performans düşüklüğünün sebebi olarak bu durum gösterilebilir. Bu nedenle, bu tür bir gerçeklemede anlamlı sonuçların elde edilebilmesi için, çekirdek parametrelerinin uygun aralıklarda seçilmesi önerilebilir. Farklı çekirdek parametreleri yerine tekli ya da çoklu parametrelerle birden fazla farklı çekirdeğin kullanılacağı çalışmalarda da bu durum göz önünde bulundurulmalıdır. Bunların dışında, ilerleyen kısımlarda bahsedilecek olan seçici TÖ stratejileri de bu dezavantajlı durumdan kurtulmak için önerilecek yaklaşımlar arasındadır. Önerilen algoritmanın çok-sınıflı sınıflandırma performansının incelenmesi de bir ileri çalışma olarak düşünülebilir.

ÇFKD algoritması oluşturulurken, belirli bir çekirdek verildiği durumda çözülmesi gereken en önemli problem (varsa) çekirdek parametresinin uygun olarak seçilmesidir. Başka bir açıdan, verilen bir ayırma/sınıflandırma görevinde örüntüler arası uzaklığı olabildiğince artıracak parametrenin bulunması istenilen performansa ulaşmada olmazsa olmaz bir konumdadır. Tez çalışması kapsamında, veriye uygun çekirdek parametresinin seçimi için bir yöntem önerilmiştir. Önerilen yöntem, sınıflar arasındaki ÇFKD ayırıcılığının artırılmasına dayanmakta ve literatürde yer alan herhangi bir optimizasyon

yaklaşımı ile çözülebilecek yapıdadır. Farklı uygulamalarda geliştirilen yöntemin bağımsız olarak test edildiği deneylerde, *Indian Pine* verisi üzerinde iki-sınıflı sınıflandırma gerçekleştirilmiştir. Deney sonuçları, önerilen yaklaşımın klasik çapraz-doğrulama yaklaşımından daha hızlı ve doğru sonuçlar ürettiğini göstermiştir. Arama süresinin uzatılması göze alınarak, Eşitlikler 3.43, 3.44 ve 3.45 ile oluşturulan optimizasyon problemi farklılaştırılabilir. Örneğin, önerilen yöntemde dikkate alınmayan sınıflar arası benzerliğin (ya da uzaklığın) eklenmesi bazı veriler için performans artışı sağlayabilir.

Hiperspektral görüntüler gibi yüksek boyutlu veriler ile çalışmanın çeşitli dezavantajları vardır. Bu dezavantajların başında, verilerin saklanması ve işlenmesi için gerekli hafızanın ve sürenin artması sayılabilir. Bu motivasyonla, literatürde mevcut olan FKD-tabanlı öznitelik çıkarma yöntemi geliştirilerek ÇFKD ile boyut azaltma algoritması önerilmiştir. FKD'nin eğiticili olması ve hedef odaklı çalışmasından dolayı önerilen tekniğin hedef tespiti ve sınıflandırma uygulamalarında gürbüz özniteliklerin çıkarılmasında kullanışlı olacağı öngörülmüştür. Önerilen yöntem hem FKD ile hem de literatürde boyut azaltma için en çok tercih edilen yaklaşım olan temel bileşen analizi (TBA) ile karşılaştırılmıştır.

İki farklı veri üzerinde hedef-arka plan ayrımı (hedef tespiti) deneyleri, geliştirilen boyut azaltma algoritmasının önceki versiyondan (FKD) ve literatürdeki klasik yaklaşımdan (TBA) üstün olduğunu göstermiştir. Özniteliklerin çıkarımından sonra ayırıcı olarak doğrusal ayırma analizinin (DAA) kullanıldığı deneylerde, önerilen yöntem, üç farklı hedef için üç farklı sınıflandırma ve tespit metriği cinsinden de en başarılı sonuçları üretmiştir. Örneğin TBA öznitelikleri ile hedeflerin DAA ile üretilen GGO değerleri yüzde 99.26, 72.58 ve 67.41 iken, ÇFKD özniteliklerinin kullanıldığı durumda bu değerler sırasıyla yüzde 99.93, 96.97 ve 92.29 çıkmıştır. Bu sonuçlar da, önerilen teknik ile boyut azaltımı sırasında hedefin ayırt edici özniteliklerinin korunduğu öngörüsünü desteklemektedir. Bunun yanında, ham özniteliklerin kullanıldığı (yani herhangi bir öznitelik çıkarımı ve seçiminin yapılmadığı durum) durumda elde edilen performans da önerilen teknikle çıkarılan özniteliklerin performansına göre düşük kalmıştır. Önerilen yaklaşımın en büyük dezavantajı olarak eğiticili ve iki-sınıflı olması söylenebilir. Başka bir ifadeyle, klasik bir hedef tespiti problemine uygulanmak istendiğinde hem arka plana hem de hedefe ait eğitim örneklerinin mevcut olması gerekecektir. Bu dezavantajı gidermek için, yine tez kapsamında geliştirilen tek-sınıflı ÇFKD (TS-ÇFKD) tekniğinin

uygulanması önerilebilir. Tez çalışmalarında, bu doğrultuda bir deneme gerçekleştirilmemiştir. Önerilen iki-sınıflı öznelik çıkarma algoritması bu haliyle DAA yaklaşımına benzemektedir. Bunun yanında, DAA sınıfların normal dağılıma sahip oldukları varsayımıyla hareket ettiğinden, DAA yerine Fisher'ın DAA tekniği ile bir karşılaştırma yürütmek daha adil olacaktır. Böyle bir durumda, hedef için kovaryans matrisi üretmenin zorluğundan bahsedilebilir. Bu zorluk, hedef eğitim örneklerinin herhangi bir dağılım fonksiyonuna uydurma için çoğunlukla yeterli olamamasından kaynaklanmaktadır. Önerilen boyut azaltma yönteminin, hedefe ait sınırlı veriye ulaşılabildiği senaryolarda test edilmesi bir devam çalışması olarak planlanmıştır.

Tez çalışmasının son ve bazı açılardan en önemli bölümünde, FKD-tabanlı sınıflandırma algoritmalarının gerçek-dünya hedef tespiti uygulamalarında doğrudan kullanılabilmesine olanak sağlayan bir teknik önerilmiştir. Hedef sınıf eğitim örneklerinin spektral özneliklerini kullanan ve bunlar yardımıyla yapay bir hedef-olmayan grup oluşturan teknik, hem UCI veri kümelerinde hem de gerçek bir hiperspektral görüntü üzerinde test edilmiştir. Klasik FKD ve ÇFKD yöntemleri ve literatürde yer alan popüler tek-sınıflı sınıflandırıcılar, tek-sınıflı DVM (TS-DVM) ve destek vektör veri tanımlama (DVVT), ile gerçekleştirilen deneyler önerilen yaklaşımın etkinliğini ortaya koymuştur.

Geliştirilen TS-FKD yönteminin düşük ve yüksek boyutlu toplamda beş adet UCI veri kümesi üzerinde gerçekleştirilen karşılaştırma testlerinde, iki veride, DVVT yöntemine sınıflandırma doğruluğu açısından geçildiği görülmüştür. Diğer üç veride ise önerilen yaklaşım en iyi sonuçları üretmiştir. RTF ile gerçekleşmiş doğrusal olmayan yöntemlerin karşılaştırmasında ise, TS-ÇFKD tüm verilerde üstün gelmekte ve verilerin çoğunda önemli bir performans artışı göstermektedir. Yine verilerin çoğunda diğer karşılaştırma yöntemlerine göre daha kararlı sonuçlar üretmiştir. Bu testlere ait sonuçlar, geliştirilen algoritmanın literatürde bilinen tek-sınıflı sınıflandırıcılara iyi bir alternatif olabileceğini vurgulamaktadır.

TS-ÇFKD algoritması tek çekirdek taşıması açısından önemli bir dezavantaja sahiptir. Tez çalışmasında çeşitli yerlerde vurgulandığı gibi, her veri ve uygulama için kullanışlı ve gürbüz genel bir çekirdekten bahsetmek mümkün değildir. Bunun yerine, birden çok çekirdek bulunan bir havuzdan kullanışlı olanların seçilmesi ve belirli kurallar çerçevesinde bir birleşimlerinin aranması üzerinde durulmaktadır. Tek-sınıflı yapıda

geliştirilen yöntemin de ÇÇÖ ve seçici ÇÇÖ yaklaşımları bu motivasyonla sağlanmıştır. ÇÇÖ probleminin çözülmesi için burada da TÖ fikrinden faydalanılmıştır. Alt-sınıflandırıcı ağırlıklarının belirlenmesi için, TS-ÇFKD'nin sınıfları ayırt ediciliği ölçülmüştür. Yapılan alt uzay analizlerinde, sınıfların tamamlayıcı özdeğerleri kullanılarak hesaplanan ağırlıkların, sınıfların ayırt edicilikleri hakkında bilgi taşıyabileceği görülmüş ve bu doğrultuda nicel bir ağırlıklandırma yöntemi önerilmiştir. İleriki kısımlarda, zayıf çekirdeklerin elenmesi ile bir seçici ÇÇÖ yaklaşımı da sunulmuştur. Çekirdeklerin güçlü ve güçsüz olarak kümelendiği bu yaklaşımda, yalnız güçlü çekirdekler kullanılarak daha yüksek performanslara ulaşılması amaçlanmıştır. Geliştirilen ÇÇÖ ve seçici ÇÇÖ yaklaşımları klasik ÇFKD için de kullanılabilir niteliktedir.

Sunulan tekli ve çoklu-çekirdek yaklaşımlarının karşılaştırılmasında, çoklu-çekirdek yönteminin (TS-ÇÇFKD) tekli yöntemine (TS-ÇFKD) göre üstünlüğü açıkça görülmektedir. Bunun yanında, önerilen seçici ÇÇÖ yaklaşımı (TS-SÇÇFKD) TS-ÇÇFKD yaklaşımına göre her zaman üstün gelememiştir. Bu durumun çeşitli sebepleri olabileceği gibi, önceden belirlenmiş çekirdek havuzunun kalitesinin etkisinden bahsedilebilir. Daha önce de belirtildiği gibi, TÖ stratejisinde alt-sınıflandırıcıların zayıf olması toplamsal başarının geliştirilmesinde önemli bir faktör olarak öne çıkmaktadır. Deneylerin bu kısmında seçilen çekirdeklerin en azından bazılarının güçlü olması, seçici yaklaşımla zayıf olanların elenmesinin etkisini ortadan kaldıracaktır. Bununla beraber, elbette, daha farklı bir çekirdek eleme yaklaşımları ile daha belirgin başarı artışlarının sağlanabileceği söylenmelidir.

DC Mall hiperspektral verisi üzerinde klasik FKD ve ÇFKD yöntemlerinin önerilen TS-FKD ve TS-ÇFKD yaklaşımları ile karşılaştırılması gerçekleştirilmiştir. Hedef tespiti testlerinde, FKD ve ÇFKD ile hem hedeften hem de arka plan karışıklığından eğitim örnekleri alınmış, TS-FKD ve TS-ÇFKD durumlarında ise yalnız hedef sınıftan örnekler veri-içinden alınmış, hedef-olmayan sınıf için gerekli örnekler sunulan yöntemle oluşturulmuştur. Farklı sayıda eğitim örnekleri ile gerçekleştirilen deneyler, önerilen yaklaşımın veriden daha az bilgi kullanmasına rağmen çoğu durumda daha başarılı olduğunu göstermiştir. Bununla birlikte, ÇFKD ve TS-ÇFKD sonuçlarının bu deneylerde birbirine yakın olduğuna dikkat edilmelidir. Ayrıca TS-ÇFKD algoritması oluşturulurken kullanılan ve hedef-olmayan örnekleri üretmeye yarayan parametrenin etkisinin yine bu deneylerde düşük kaldığı görülmüştür. Bu sonuçlar doğrultusunda, önerilen FKD-tabanlı

TS sınıflandırma yöntemleri ile uzaktan algılama verilerinde hedef tespiti uygulamalarının genel olarak anlamlı bir biçimde yapılabileceği söylenebilir.

Tez çalışmasının bu kısmında da, tezin genelinde olduğu gibi çok-sınıflı sınıflandırma üzerinde ayrıntılı olarak durulmamıştır. Çok-sınıflı sınıflandırma uygulamaları literatürde sıkça başvurulan bire-karşı-bir veya bire-karşı-hepsi gibi klasik stratejiler ile gerçekleştirilebileceği gibi, bu testlerin performans sonuçları ileri bir çalışma olarak düşünülebilir. Bunun dışında, geliştirilen TS sınıflandırma yöntemleri aykırı değer, yenilik ve değişim tespiti gibi diğer veri tanımlama problemleri için de kullanılacak şekilde düzenlenebilir. Deneylede kullanılan çekirdeklerin çeşitliliklerinin ve sayılarının değişiminin etkisinin incelenmesi de yine bir ileri çalışma olarak planlanabilir.



KAYNAKLAR

- [1] Manolakis, D. ve Shaw, G., (2002). "Detection algorithms for hyperspectral imaging applications", IEEE Signal Processing Magazine, 19(1):29-43.
- [2] Sims, S. R. F. ve Mahalanobis, A., (2004). "Performance evaluation of quadratic correlation filters for target detection and discrimination in infrared imagery", Optical Engineering, 43:1705-1711.
- [3] Bal, A. ve Alam, M. S., (2005). "Quadratic correlation filter-based target tracking in FLIR image sequences", Proc. SPIE Applications of Digital Image Processing XXVIII, 5909:590906.
- [4] Fukunaga, K. ve Koontz, W. L. G., (1970). "Applications of the Karhunen-Loève expansion to feature selection and ordering", IEEE Transaction on Computers, 19(5):311-318.
- [5] Liu, R., Liu, E., Yang, J., Zhang, T. ve Wang, F., (2007). "Infrared small target detection with kernel Fukunaga-Koontz transform", Meas. Sci. Technol, 18(9):3025-3035.
- [6] Huo, X., Elad, M., Flesia, A. G., Muise, R. R., Stanfill, S. R., Friedman, J. ve Donoho, D. L. (2003). "Optimal reduced-rank quadratic classifiers using the Fukunaga-Koontz transform with applications to automated target recognition", International Society for Optics and Photonics, 59-72.
- [7] Yang, M.-H., Kriegman, D. J. ve Ahuja, N., (2002). "Detecting Faces in Images: A Survey", IEEE Trans. Pattern Analysis and Machine Intelligence, 24(1):34-58.
- [8] Kim, K., Franz, M. O. ve Schölkopf, B., (2005). "Iterative kernel principal component analysis for image modeling", IEEE Trans. Pattern Anal. Mach. Intell., 27(9):1351-1366.
- [9] Li, Y-H. ve Savvides, M., (2007). "Kernel Fukunaga-Koontz transform subspaces for enhanced face recognition", IEEE Conf. on Computer Vision and Pattern Recognition (CVPR 2007), 1-8.
- [10] Dinç, S. ve Bal, A., (2013). "Hyperspectral image classification using kernel Fukunaga-Koontz transform", Mathematical Problems in Engineering.
- [11] Zhang, D.-Q., Zhou, Z.-H. ve Chen, S. C., (2006). "Adaptive kernel principal component analysis with unsupervised learning of kernels", Proceedings of the 6th IEEE International Conference on Data Mining (ICDM), 1178-1182.

- [12] Binol, H., Bilgin, G., Dinc, S. ve Bal, A., (2015). "Kernel Fukunaga-Koontz Transform Subspaces for Classification of Hyperspectral Images with Small Sample Sizes", *IEEE Geosci. and Rem. Sens. Letters*, 12(6):1287-1291.
- [13] Binol, H., Bal, A. ve Cukur, H., (2015). "Differential evolution algorithm-based kernel parameter selection for Fukunaga-Koontz Transform subspaces construction", *Proc SPIE9646, High-Performance Computing in Remote Sensing V*.
- [14] Ilonen, J., Kamarainen, J. K. ve Lampinen, J., (2003). "Differential evolution training algorithm for feed-forward neural networks", *Neural Processing Letters*, 17(1):93-105.
- [15] Bach, F. R., Lanckriet, G. R. G. ve Jordan, M. I., (2004). "Multiple kernel learning, conic duality, and the SMO algorithm", *Proceedings of the twenty-first international conference on Machine learning*, 6.
- [16] Lanckriet, G. R. G., Cristianini, N., Bartlett, P., El Ghaoui, L. ve Jordan, M. I., (2004). "Learning the Kernel Matrix with Semidefinite Programming", *J. of Machine Learning Research*, 5:27-72.
- [17] De Diego, I. M., Moguerza, J. M. ve Muoz, A., (2004). "Combining Kernel Information for Support Vector Classification", *Proc. 5th Int'l Workshop Multiple Classifier Systems*, 102-111.
- [18] Ong, C. S., Smola, A. J. ve Williamson, R. C., (2005). "Learning the kernel with hyperkernels", *Journal of Machine Learning Research*, 6:1043-1071.
- [19] Xu, X., Tsang, I. W. ve Xu, D., (2013). "Soft margin multiple kernel learning", *IEEE Trans. Neural Netw. Learn. Syst.*, 24(5):749-761.
- [20] Lee, W.-J., Verzakov, S. ve Duin, R. P. W., (2007). "Kernel combination versus classifier combination", *Proceedings of the 7th international conference on Multiple classifier systems*, Berlin, Heidelberg: Springer-Verlag, 22-31.
- [21] Chang, C. I., (Ed.). (2007). *Hyperspectral data exploitation: theory and applications*. John Wiley and Sons.
- [22] Camps-Valls, G., Gomez-Chova, L., Muñoz-Marí, J., Vila-Francés, J. ve Calpe-Maravilla, J., (2006). "Composite kernels for hyperspectral image classification", *IEEE Geoscience and Remote Sensing Letters*, 3(1):93-97.
- [23] Sun, T., Jiao, L., Liu, F., Wang, S. ve Feng, J., (2013). "Selective multiple kernel learning for classification with ensemble strategy", *Pattern Recognition*, 46(11):3081-3090.
- [24] Gehler, P. ve Nowozin, S., (2009). "On feature combination for multiclass object classification", *Proc. IEEE Conf. Computer Vision*, 221-228.
- [25] Lin, Y. Y., Tsai, J. F. ve Liu, T. L., (2009). "Efficient discriminative local learning for object recognition", *Proc. IEEE Conf. Computer Vision*, 598-605.
- [26] Xia, H. ve Hoi, S. C. H., (2013). "Mkboost: A framework of multiple kernel boosting", *IEEE Trans. Knowledge and Data Engineering*, 25(7):1574-1586.
- [27] Scott, D. W., (1992). *The Curse of dimensionality and Dimension Reduction in Multivariate Density Estimation: Theory, Practice, and Visualization*, Chapter 7, John Wiley and Sons, Inc., 195-217.

- [28] Kaewpijit, S., Le Moigne, J. ve El-Ghazawi, T., (2003). "Automatic reduction of hyperspectral imagery using wavelet spectral analysis", IEEE Trans. Geosci. Remote Sens., 41(4):863-871.
- [29] Jimenez, L. ve Landgrebe, D. A., (1999). "Hyperspectral data analysis and supervised feature reduction via projection pursuit", IEEE Trans. Geosci. Remote Sens., 37(6):2653-2667.
- [30] Richards, J. A., (1993). Remote Sensing Digital Image Analysis. Berlin, Germany: Springer-Verlag.
- [31] Cohen, J., (1960). "A coefficient of agreement for nominal scales", Educational and Psychological Measurement, 20(1):37-46.
- [32] Landgrebe, D. A., (1999). Signal Theory Methods in Multispectral Remote Sensing, John Wiley and Sons, Hoboken, NJ, USA.
- [33] Lennon, M. (2002). Méthodes d'analyse d'images hyperspectrales, exploitation du capteur aéroporté CASI pour des applications de cartographies agro-environnementale en Bretagne, Ph.D. dissertation, Université de Rennes, Rennes, France.
- [34] Journaux, L., Tizon, X., Foucherot, I. ve Gouton, P., (2006). "Dimensionality reduction techniques: an operational comparison on multispectral satellite images using unsupervised clustering", Proceedings of the 7th Nordic Signal Processing Symposium (NORSIG'06), 242-245, Reykjavik, Iceland.
- [35] Lennon, M., Mercier, G., Mouchot, M. C. ve Hubert-Moy, L., (2002). "Curvilinear component analysis for nonlinear dimensionality reduction of hyperspectral images," in Image and Signal Processing for Remote Sensing VII, vol. 4541 of Proceedings of SPIE, 157-168, Toulouse, France.
- [36] Ochilov, S., Alam, M. S. ve Bal, A., (2006). "Fukunaga-Koontz transform based dimensionality reduction for hyperspectral imagery", Proc. SPIE 6233, Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XII, 62332A.
- [37] Binol, H., Ochilov, S., Alam, M. S. ve Bal, A. "Target Oriented Dimensionality Reduction of Hyperspectral Data by Kernel Fukunaga-Koontz Transform", Optics and Lasers in Engineering. (Kabul Edildi, Basım Aşamasında)
- [38] Binol, H. ve Bal, A., (2016). "Supervised target detection in hyperspectral images using one-class Fukunaga-Koontz transform", Proc. SPIE 9842, Signal Processing, Sensor/Information Fusion, and Target Recognition XXV. Baltimore, Maryland, USA.
- [39] Campbell, J. B. ve Wynne, R. H., (2011). Introduction to remote sensing, Guilford Press.
- [40] Hiperspektral görüntüleme sistemi, http://www.csiro.au/news/-newsletters/0611_metals/story2.htm, 7 Mayıs 2012.
- [41] Manolakis, D., Marden, D. ve Shaw, G. A., (2003). "Hyperspectral image processing for automatic target detection applications", Lincoln Laboratory Journal, 14(1):79-116.

- [42] Shaw, G. ve Manolakis, D., (2002). "Signal processing for hyperspectral image exploitation", IEEE Signal processing magazine, 19(1):12-16.
- [43] Wang, L. ve Zhao, C., (2015). Hyperspectral Image Processing. Springer.
- [44] Hughes, G., (1968). "On the mean accuracy of statistical pattern recognizers", IEEE transactions on information theory, 14(1):55-63.
- [45] Bellman, R. E., (2015). Adaptive control processes: a guided tour. Princeton University Press.
- [46] Jia, X., Kuo, B. C., ve Crawford, M. M., (2013). "Feature mining for hyperspectral image classification", Proceedings of the IEEE, 101(3), 676-697.
- [47] Liu, R., Liu, E., Yang, J., Zeng, Y., Wang, F. ve Cao, Y., (2007). "Automatically detect and track infrared small targets with kernel Fukunaga-Koontz transform and Kalman prediction", Applied Optics, 46(31):7780-7791.
- [48] Zhang, S. ve Sim, T., (2007). "Discriminant subspace analysis: A Fukunaga-Koontz approach", IEEE Transactions on Pattern Analysis and Machine Intelligence, 29(10):1732-1745.
- [49] Mahalanobis, A., Muise, R. R., Stanfill, S. R. ve Nevel, A. V., (2004). "Design and application of quadratic correlation filters for target detection", IEEE Trans. Aerosp. Electron. Syst., 40(3):837-850.
- [50] Aizerman, M., Braverman, E. ve Rozonoer, L., (1964). "Theoretical foundations of the potential function method in pattern recognition learning", Automation and Remote Control, 25:821-837.
- [51] Shawe-Taylor, J. ve Cristianini, N., (2004). Kernel Methods for Pattern Analysis, Cambridge University Press.
- [52] Yang, J., Frangi, A. F., Yang, J. Y., Zhang D. ve Jin, Z., (2005). "KPCA plus LDA: A complete kernel Fisher discriminant framework for feature extraction and recognition", IEEE Trans. Pattern Anal. Mach. Intelligence, 27:230-244.
- [53] Vapnik, V. N. ve Vapnik, V., (1998). Statistical learning theory. New York: Wiley.
- [54] Rakotomamonjy, A., Bach, F., Canu, S. ve Grandvalet, Y., (2008). "SimpleMKL", Journal of Machine Learning Research, 9:2491-2521.
- [55] Kuo, B.-C. ve Landgrebe, D. A., (2002). "A covariance estimator for small sample size classification problems and its application to feature extraction", IEEE Trans. Geoscience and Remote Sensing, 40(4):814-819.
- [56] Miranda, A. A. ve Whelan, P. F., (2005). "Fukunaga-Koontz transform for small sample size problems", Proc. IEEE Irish Signals and Systems Conference (ISSC), Dublin, Ireland, 156-161.
- [57] AVIRIS NW Indiana's Indian Pines 1992 Data Set. (Orijinal dosyalar) ve (yerdöğrülüğü): <https://engineering.purdue.edu/~biehl/MultiSpec/hyperspectral.html>, 25 Mart 2013.
- [58] DC Mall image and band specifications for the HYDICE Washington D.C. Mall image, http://www.lars.purdue.edu/home/image_data/hydice_dc_wavelengths.html, 25 Mart 2013.

- [59] Faulconbridge, R. I. ve Pickering, M. R., (2006). "Unsupervised band removal leading to improved classification accuracy of hyperspectral images", Proceedings of the 29th Australasian Computer Science Conference, Avusturalya.
- [60] Rajadell, O. ve Garc'ia-Sevilla, P., (2009). "Textural Features for Hyperspectral Pixel Classification", Proceedings of the 4th Iberian Conference on Pattern Recognition and Image Analysis, Portekiz, 208-216.
- [61] Snyder, D., Kerekes, J., Fairweather, I., Crabtree, R., Shive, J. ve Hager, S., (2008). "Development of a web-based application to evaluate target finding algorithms" Proc. IEEE Int. Geosci. Remote Sens. Symp., 2:915-918.
- [62] Kim, H. C., Pang, S., Je, H. M., Kim, D. ve Bang, S. Y., (2002). "Support vector machine ensemble with bagging", Pattern recognition with support vector machines, 397-408. Springer Berlin Heidelberg.
- [63] Lichman, M., (2013). UCI Machine Learning Repository, School Inf. Comput. Sci., Univ. California, Irvine, CA, USA, <http://archive.ics.uci.edu/ml>, 10 Mart 2016.
- [64] Gonzalez, R. C. ve Woods, R. E., (2008). Digital image processing.
- [65] Schowengerdt, R. A., (2006). Remote sensing: models and methods for image processing. Academic press.
- [66] Cheriadat, A. ve Bruce, L. M., (2003). "Why principal component analysis is not an appropriate feature extraction method for hyperspectral data", IEEE Geoscience and Remote Sensing Symposium, 6:3420-3422.
- [67] Karlholm, J. ve Renhorn, I., (2002). "Wavelength band selection method for multispectral target detection", Applied Optics, 41(32):6786-6795.
- [68] Holzwarth, S., Muller, A., Habermeyer, M., Richter, R., Hausold, A., Thiemann, S. ve Strobl, P., (2003). "HySens-DAIS 7915/ROSIIS imaging spectrometers at DLR", Proceedings of the 3rd EARSeL Workshop on Imaging Spectroscopy, 3-14.
- [69] Pavia Üniversitesi hiperspektral verisi, http://www.ehu.es/ccwintco/index.php?title=Hyperspectral_Remote_Sensing_Scenes, 1 Mart 2014.
- [70] Demirci, S., Erer, I. ve Ersoy, O., (2014). "Vector tunnel algorithm for hyperspectral target detection", Proc. SPIE9088-12, Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery.
- [71] Tumer, K. ve Ghosh, J., (1996). "Error correlation and error reduction in ensemble classifiers", Connection science, 8(3-4):385-404.
- [72] Mao, S., Jiao, L. C., Xiong, L. ve Gou, S., (2011). "Greedy optimization classifiers ensemble based on diversity", Pattern Recognition, 44(6):1245-1261.
- [73] Binol, H., Uslu, F. S. ve Bal, A., (2015). "Unsupervised Nonlinear Feature Extraction Method And Its Effects On Target Detection In High-Dimensional Data", International Journal of Electrical, Electronics and Data Communication, 3(8):43-46.

- [74] Zhang, D., Chen, S. ve Zhou, Z. H., (2006). “Learning the kernel parameters in kernel minimum distance classifier”, *Pattern Recognition*, 39(1):133-135.
- [75] Manevitz, L. M., ve Yousef, M., (2001). “One-class SVMs for document classification”, *Journal of Machine Learning Research*, 2:39-154.
- [76] Tax, D. M., ve Duin, R. P., (2004). “Support vector data description”, *Machine learning*, 54(1):45-66.
- [77] Chang, C. C., ve Lin, C. J., (2011). “LIBSVM: a library for support vector machines”, *ACM Transactions on Intelligent Systems and Technology (TIST)*, 2(3):27.



ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Hamidullah BİNOL
Doğum Tarihi ve Yeri : 06.02.1988 - GİRESUN
Yabancı Dili : İngilizce
E-posta : hbinol@yildiz.edu.tr

ÖĞRENİM DURUMU

Derece	Alan	Okul/Üniversite	Mezuniyet Yılı
Yüksek Lisans	Elektronik ve Haberleşme Müh. A.B.D. / Haberleşme Programı	Yıldız Teknik Üniversitesi	2012
Lisans	Telekomünikasyon Mühendisliği	İstanbul Teknik Üniversitesi	2010
Lise	Fen Bilimleri	Konya Meram Fen Lisesi	2005

İŞ TECRÜBESİ

Yıl	Kurum	Görevi
2010 –	Yıldız Teknik Üniversitesi	Araştırma Görevlisi

YAYINLARI

Makale

1. **Binol, H.**, Ochilov, S., Alam, M. S., ve Bal, A. (2017). Target Oriented Dimensionality Reduction of Hyperspectral Data by Kernel Fukunaga-Koontz Transform. *Optics and Lasers in Engineering*, 89, 123-130.
2. Uslu, F. S., **Binol, H.**, Ilarslan, M., ve Bal, A. (2017). Improving SVDD Classification Performance on Hyperspectral Images Via Correlation Based Ensemble Technique. *Optics and Lasers in Engineering*, 89, 169-177.
3. **Binol, H.**, Cukur, H, ve Bal, A. (2016). A Supervised Discriminant Subspaces-based Ensemble Learning for Binary Classification. *International Journal of Advanced Computer Research*, 6(27), 209-214.
4. Korkmaz, S. A., Poyraz, M., Bal, A., **Binol, H.**, Özercan, İ. H., Korkmaz, M. F., ve Aydın, A. M. (2015). New Methods Based on mRMR_LSSVM and mRMR_KNN for Diagnosis of Breast Cancer from Microscopic and Mammography Images of Some Patients. *Int. J. of Biomedical Engineering and Technology*, 19(2), 105-117.
5. **Binol, H.**, Uslu, F. S., ve Bal, A. (2015). Unsupervised Nonlinear Feature Extraction Method And Its Effects On Target Detection In High-Dimensional Data. *International Journal of Electrical, Electronics and Data Communication*, 3(8), 43-46.
6. **Binol, H.**, Bilgin, G., Dinç, S., ve Bal, A. (2015). Kernel Fukunaga-Koontz Transform Subspaces for Classification of Hyperspectral Images with Small Sample Sizes. *IEEE Geoscience and Remote Sensing Letters*, 12(6), 1287-1291.

Bildiri

1. Salturk, S., Bal, A., ve **Binol, H.** (2016, Mayıs). Target Detection in Hyperspectral Imagery Combining Spectral and Spatial Features. 3rd

International Conference on Future Computational Technologies (ICFCT'2016). Istanbul, Turkey.

2. Bal, A., Uslu, F. S., ve **Binol, H.** (2016, Nisan). Food inspection using hyperspectral imaging and SVDD. Proc. SPIE 9864, Sensing for Agriculture and Food Quality and Safety VIII. Baltimore, Maryland, USA.
3. Cukur, H., **Binol, H.**, Bal, A., ve Yavuz, F. (2016, Nisan). Covariance descriptor fusion for target detection. Proc. SPIE 9842, Signal Processing, Sensor/Information Fusion, and Target Recognition XXV. Baltimore, Maryland, USA.
4. **Binol, H.**, ve Bal, A. (2016, Nisan). Supervised target detection in hyperspectral images using one-class Fukunaga-Koontz transform. Proc. SPIE 9842, Signal Processing, Sensor/Information Fusion, and Target Recognition XXV. Baltimore, Maryland, USA.
5. **Binol, H.**, ve Bal, A. (2016, Ocak). Hyperspectral Imaging and Nonlinear Fukunaga-Koontz Transform Based Food Inspection. 18th International Conference on Communications, Control and Signal Processing (ICCCSP). Jeddah.
6. Cukur, H., **Binol, H.**, Uslu, F. S., Kalaycı, Y., ve Bal, A. (2015, Kasım). Cross Correlation Based Clustering for Feature Selection in Hyperspectral Imagery. 9th International Conference on Electrical and Electronics Engineering (ELECO). Bursa, Turkey.
7. **Binol, H.**, Bal, A., ve Çukur, H. (2015, Eylül). Differential evolution algorithm-based kernel parameter selection for Fukunaga-Koontz Transform Subspaces Construction. The 22nd SPIE Symposium on Remote Sensing. Toulouse, France.
8. Cukur, H., **Binol, H.**, Uslu, F. S., ve Bal, A. (2015, Eylül). An Effective Band Selection Approach for Classification in Remote Sensing Imagery. The 22nd SPIE Symposium on Remote Sensing.

Toulouse, France.

9. Uslu, F. S., **Binol, H.**, Bal, A., ve Çukur, H. (2015, Temmuz). SVDD Fusion Based Classification in Hyperspectral Imagery. 2nd International Conference on Engineering and Natural Science (ICENS). Japan.
10. Uslu, F. S., Bal, A., ve **Binol, H.** (2015, Haziran). An Efficient Classifier Design for Remote Sensing Hyperspectral Imagery. International Conference on Recent Advances in Space Technologies (RAST). Istanbul.
11. Cukur, H., **Binol, H.**, ve Bal, A. (2015, Mayıs). Hiperspektral Görüntülerde Sınıflama Başarısını Artırmaya Yönelik Sezgisel Band Seçimi Yaklaşımı. IEEE 23. Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SİU). Malatya, Türkiye.
12. **Binol, H.**, ve Bal, A. (2012, Ekim). Gabor Dönüşümü Tabanlı Bölge Kovaryans Matrisleri İle Hiperspektral Görüntülerde Sınıflandırma. 3. Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu (UZAL-CBS). Zonguldak, Türkiye.
13. **Binol, H.**, Dinç, S., ve Bal, A. (2012, Nisan). Geliştirilmiş Kovaryans Tanımlayıcı Kullanarak Hiperspektral Görüntülerde Sınıflandırma. IEEE 20. Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SİU). Muğla, Türkiye.

Proje

1. Uyarlamalı Çekirdek tabanlı Fukunaga-Koontz Dönüşümü ile Hiperspektral Görüntülerde Hedef Tespiti
Projedeki Görevi: Araştırmacı **Destekleyen Kurum:** BAP
Başlangıç/Bitiş: (2015-2018)
2. Hiperspektral Görüntülerde Boyut İndirgeme ve Hedef Tespiti
Projedeki Görevi: Araştırmacı **Destekleyen Kurum:** HAVELSAN

Başlangıç/Bitiş: (2014-2015)

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

Projedeki Görevi: Bursiyer **Destekleyen Kurum:** TÜBİTAK

Başlangıç/Bitiş: (2013-2016)

Patent

1. Hiperspektral Görüntülerde Hedef Tespiti için Bir Yöntem

Kapsam: Ulusal **Durum:** Bekliyor