

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

**TOPLULUK ÖĞRENMELİ DESTEK VEKTÖR VERİ
TANIMLAMASI YÖNTEMİ İLE HİPERSPEKTRAL
GÖRÜNTÜLERİN SINIFLANDIRILMASI**

FARUK ŞÜKRÜ USLU

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

**DANIŞMAN
PROF. DR. HERMAN SEDEF**

İSTANBUL, 2017

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

TOPLULUK ÖĞRENME Lİ DESTEK VEKTÖR VERİ
TANIMLAMASI YÖNTEMİ İLE HİPERSPEKTRAL
GÖRÜNTÜLERİN SINIFLANDIRILMASI

Faruk Şükrü USLU tarafından hazırlanan tez çalışması 12.05.2017 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

Yrd. Doç. Dr. Gökhan BİLGİN
Yıldız Teknik Üniversitesi

Yrd. Doç. Dr. Tolga ENSARİ
İstanbul Üniversitesi

Prof. Dr. Sedef Kent PINAR
İstanbul Teknik Üniversitesi

Yrd. Doç. Dr. Nihan KAHRAMAN
Yıldız Teknik Üniversitesi

ÖNSÖZ

Bu tezin hazırlanması süresi boyunca, bilgisi, deneyimini paylaşan ve desteklerini esirgemeyen tez danışmanım Sayın Prof.Dr. Herman SEDEF'e ve sağladıkları uygun çalışma ortamı nedeniyle Elektronik ve Haberleşme Mühendisliği Bölümü ailesine teşekkürlerimi sunuyorum.

Ayrıca, çalışmalarım boyunca değerli zamanını ve tecrübesini benden esirgemeyerek çalışmalarına büyük katkı sağlayan, beni sürekli motive edip zorlukları kolaylaştıran kıymetli hocam Yrd. Doç. Dr. Gökhan BİLGİN'e ve Tez İzleme Komitesi üyesi Sayın Yrd. Doç. Dr. Tolga ENSARİ desteklerinden dolayı teşekkürü bir borç bilirim.

Burada isimlerini tek tek sıralayamadığım, samimi yardım ve desteklerini sürekli hissettiğim başta annem, babam ve ailem olmak üzere yakın çevremdeki ve mesai ortamındaki dost ve arkadaşlarıma da şükranlarımı sunmadan geçemeyeceğim.

Hepsin ötesinde, çalışmalarım boyunca göz ardı edilemez hoşgörü ve sonsuz desteğini bana olan sevgisiyle vermiş olan eşim Nurcihan USLU'ya özel takdirlerimi sunuyorum. Her şeyin bir bedeli olduğu gerçeğinden hareketle bu bedeli benimle birlikte çektikleriyle ve yaptıkları fedakârlıklarla ödeyen eşim ve harika çocuklarım Gürkan Emre, Zeynep Nurşen ve Hakkı Erdem'e minnettarım. Onların muhteşem destekleri ve anlayışları olmadan bu zorlu süreci hiçbir zaman başaramazdım.

Mayıs, 2017

Faruk Şükrü USLU

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.....	6
1.3 Hipotez.....	7
BÖLÜM 2	
TEORİK ALTYAPI.....	9
2.1 Sınır Betimlemeli Tek Sınıf Sınıflandırıcılar (TSS)	9
2.1.1 Destek Vektör Veri Tanımlaması (DVVT)	9
2.1.2 Tek Sınıf Destek Vektör Makinası (TSDVM).....	11
2.1.3 Çekirdek Fonksiyonları	11
2.2 Topluluk Öğrenme Yöntemi	13
2.2.1 Çeşitlilik (Diversity)	14
2.2.2 Birleştirme Yöntemleri ve Oylama	17
2.2.3 Torbalama	18
BÖLÜM 3	
HİPERSPEKTRAL VERİ SETLERİ VE PERFORMANS DEĞERLENDİRME ÖLÇÜTLERİ	20
3.1 Hiperspektral Veri Setleri	20
3.1.1 Kennedy Space Center (KSC) Veri Seti	20
3.1.2 Salina Valley Veri Seti	21
3.1.3 Botswana Veri Seti	21

3.1.4	Pavia University Veri Seti	22
3.1.5	Washington, DC Mall Veri Seti.....	23
3.2	Performans Değerlendirme Ölçütleri.....	24

BÖLÜM 4

TOPLULUK ÖĞRENME YÖNTEMİ İLE DVVT SINIFLANDIRMA PERFORMANSININ GELİŞTİRİLMESİ	27
--	----

4.1	Giriş	27
4.2	Deneysel Model.....	27
4.2.1	Önerilen Ağırlıklandırma ve Birleştirme Yöntemi.....	27
4.2.2	Parametre Seçimi	29
4.3	Deneysel Sonuçlar	29
4.3.1	KSC HiperSpektral Veri Seti için Deneysel Sonuçlar	29
4.3.2	Botswana HiperSpektral Veri Seti için Deneysel Sonuçlar	31
4.3.3	Pavia University HiperSpektral Veri Seti için Deneysel Sonuçlar	32
4.3.4	Alt Eğitim Veri Seti Sayısına Göre Değerlendirme Sonuçları.....	34
4.4	Değerlendirme	35

BÖLÜM 5

HİPERSPEKTRAL HEDEF TESPİTİ İÇİN KÜÇÜK EĞİTİM SETİ İLE ÇEKİRDEK PARAMETRESİ DEĞİŞİMLİ TOPLULUK ÖĞRENME YÖNTEMİ ÖNERİMİ	36
---	----

5.1	Giriş	36
5.2	Deneysel Model.....	37
5.2.1	Önerilen Algoritma	37
5.2.2	Parametre Seçimi	37
5.3	Deneysel Sonuçlar	38
5.3.1	DC Mall HiperSpektral Veri Seti için Deneysel Sonuçlar	38
5.3.2	Salinas Valley HiperSpektral Veri Seti için Deneysel Sonuçlar	39
5.3.3	Farklı Büyüklükteki Eğitim Setleri için Deneysel Sonuçlar.....	42
5.4	Değerlendirme	43

BÖLÜM 6

HİPERSPEKTRAL SINIFLANDIRMA/HEDEF TESPİTİ PROBLEMİNDE TOPLULUK ÖĞRENME YÖNTEMİNDE ÇEŞİTLİLİK İÇİN YENİ BENZERLİK METRİĞİ ÖNERİMİ	45
--	----

6.1	Giriş	45
6.2	Önerilen Benzerlik Metriği	46
6.3	Deneysel Model.....	47
6.3.1	Yeni Benzerlik Metriği ile Önerilen Algoritma.....	47
6.3.2	Parametre Seçimi	49
6.4	Deneysel Sonuçlar	50
6.4.1	Salinas Valley HiperSpektral Veri Seti için Deneysel Sonuçlar	50
6.4.2	Pavia University HiperSpektral Veri Seti için Deneysel Sonuçlar	53
6.4.3	Botswana HiperSpektral Veri Seti için Deneysel Sonuçlar	56
6.5	Değerlendirme	60

BÖLÜM 7

SONUÇ VE ÖNERİLER.....	61
KAYNAKLAR	64
ÖZGEÇMİŞ	71



SİMGE LİSTESİ

a	İki sınıflandırıcı'nın (C_i, C_j) hedef sınıf olarak tespit ettiği eşleşme sayısı
a	Hiperküre merkezi
b	C_i sınıflandırıcısının hedef olarak tespit ettiği ancak C_j sınıflandırıcısının hedef olmayan sınıf olarak tespit ettiği eşleşme sayısı
c	C_i sınıflandırıcısının hedef olmayan sınıf olarak tespit ettiği ancak C_j sınıflandırıcısının hedef sınıf olarak tespit ettiği eşleşme sayısı
C	Cezalandırma faktörü
C_i	i . sınıflandırıcı
d	İki sınıflandırıcı'nın (C_i, C_j) hedef olmayan sınıf olarak tespit ettiği eşleşme sayısı
D	Farklılık metriği
f	Sınıflandırıcı veya karar sonucu
K	Çekirdek fonksiyonu
L	Eğitim örnek veri sayısı
M	Topluluk öğrenmedeki taban sınıflandırıcı sayısı
R	Hiperküre yarıçapı
S	Benzerlik metriği
w	Normal vektör
w_i	i . sınıflandırıcı ağırlık katsayısı
X_1	Eğitim veri seti
\bar{x}	Verilerin merkez noktası
y_i	Test veri örneği
ξ_i	Gevşeklik değişkeni
σ	RTF parametresi
ρ	Hiperdüzlemin orijinden olan uzaklığı
ρ	Korelasyon katsayısı
α_i	Destek vektörleri
v	Yanlış sınıflandırılan değerlerin izin verilen oranı
ϕ	Haritalama fonksiyonu

KISALTMA LİSTESİ

3D	Üç boyutlu
AdaBoost	Adaptive Boosting
AO	Ağırlıklı Oylama
ATÖ	Ağırlıklı Topluluk Öğrenme
AVIRIS	Airborne Visible/Infrared Imaging Spectrometer
Bagging	Bootstrap Aggregating
BE	Basit Eşleme
ÇA	Çift Arıza
ÇÇÖ	Çok Çekirdekli Öğrenme
ÇÖ	Çoğunluk Oylaması
DO	Döndürme Ormanı
DSO	Dengeli Sınıflandırma Oranı
DVM	Destek Vektör Makinası
DVVT	Destek Vektör Veri Tanımlaması
FM	F-Metriği
FN	False Negatif
FP	False Pozitif
HSG	Hiperspektral Görüntü
HYDICE	Hyperspectral Digital Imagery Collection Experiment
KÖS	Küçük Örnek Sayısı
KSC	Kennedy Space Center
LWIR	Long Wavelength Infrared (5-11 μm)
MWIR	Mid-wavelength Infrared (3-5 μm)
NIR	Near Infrared (0.7-1.5 μm)
OSO	Ortalama Sınıflandırma Oranı
OSS	Ortalama Sıra Skoru
PTD	Pozitif Tahmin Değeri
RGB	Red Green Blue
ROSI	Reflective Optics System Imaging Spectrometer
RTF	Radyal Tabanlı gauss çekirdek Fonksiyonu
STÖ	Seçmeli Topluluk Öğrenme
SWIR	Short Wavelength Infrared (1.5-3 μm)
TN	True Negatif
TNO	True Negatif Oranı
TÖ	Topluluk Öğrenme
TÖ-DVVT	Topluluk Öğrenmeli Destek Vektör Veri Tanımlaması
TP	True Pozitif
TPO	True Pozitif Oranı
TSDVM	Tek Sınıf Destek Vektör Makinası

TSS Tek Sınıf Sınıflandırıcı
VNIR Visible and Near-InfraRed (0.4-1.5 μm)
YSA Yapay Sinir Ağları
YTÜ Yıldız Teknik Üniversitesi



ŞEKİL LİSTESİ

	Sayfa
Şekil 1.1	Görünür ve kızılötesi spektral bantlar 1
Şekil 1.2	Hiperspektral görüntüleme 3D hiperküp (orta resim). Bir piksele ait spektral imza ve tek dalga boyuna ait görüntü..... 2
Şekil 2.1	Hedef sınıfı içeren merkez, a ve yarıçap, R ile tanımlanmış hiperküre 10
Şekil 2.2	Hedef verilerini orjinden maksimum mesafede ayıran hiperdüzlem 11
Şekil 2.3	Doğrusal dağılım elde etmek için haritalama yaklaşımı örneği..... 12
Şekil 3.1	KSC verisi (a) RGB görüntüsü (b) kesin referans haritası 21
Şekil 3.2	Salinas valley verisi (a) tekli spektral bant görüntüsü (b) kesin referans haritası 21
Şekil 3.3	Botswana verisi (a) RGB görüntüsü (b) kesin referans haritası. 22
Şekil 3.4	Pavia university verisi (a) RGB görüntüsü (b) kesin referans haritası 23
Şekil 3.5	Washington, DC Mall verisi (a) döndürülmüş üç kanal yapay görüntüsü (kullanılan bantlar R:60, G:27, B:17) (b) kesin referans haritası 23
Şekil 4.1	KSC verisi için sınıflandırma haritaları (a) klasik DVVT (b) çoğunluk oylamalı TÖ-DVVT (c) ağırlık oylamalı (konik) TÖ-DVVT (d) ağırlık oylamalı (konveks) TÖ-DVVT 30
Şekil 4.2	Botswana verisi için sınıflandırma haritaları (a) klasik DVVT (b) çoğunluk oylamalı TÖ-DVVT (c) ağırlık oylamalı (konik) TÖ-DVVT (d) ağırlık oylamalı (konveks) TÖ-DVVT 32
Şekil 4.3	Pavia university verisi için sınıflandırma haritaları (a) klasik DVVT (b) çoğunluk oylamalı TÖ-DVVT (c) ağırlık oylamalı (konik) TÖ-DVVT (d) ağırlık oylamalı (konveks) TÖ-DVVT 34
Şekil 4.4	KSC S3 sınıfı için alt eğitim veri seti sayısına karşı hesaplanan ortalama DSO sonuçları..... 34
Şekil 4.5	Botswana S8 sınıfı için alt eğitim veri seti sayısına karşı hesaplanan ortalama DSO sonuçları. 35
Şekil 6.1	Salinas valley verisi için eğitim seti büyüklüklerine göre ortalama FM sonuçları (a) DVVT (b) TSDVM..... 51
Şekil 6.2	Salinas valley verisi için eğitim seti büyüklüklerine göre ortalama DSO sonuçları (%) (a) DVVT (b) TSDVM..... 52
Şekil 6.3	Pavia university verisi için eğitim seti büyüklüklerine göre ortalama FM sonuçları (a) DVVT (b) TSDVM..... 54
Şekil 6.4	Pavia university verisi için eğitim seti büyüklüklerine göre ortalama DSO sonuçları (%) (a) DVVT (b) TSDVM..... 55
Şekil 6.5	Botswana verisi için eğitim seti büyüklüklerine göre ortalama FM sonuçları (a) DVVT (b) TSDVM 58
Şekil 6.6	Botswana verisi için eğitim seti büyüklüklerine göre ortalama DSO sonuçları (%) (a) DVVT (b) TSDVM..... 58

ÇİZELGE LİSTESİ

	Sayfa
Çizelge 2.1	İki sınıflandırıcının olumsuzluk tablosu 16
Çizelge 3.1	Hiperspektral veri kümelerindeki sınıf isimleri ve kesin referans piksel sayıları 24
Çizelge 3.2	Karışıklık matrisi..... 24
Çizelge 4.1	KSC veri seti için hesaplanan klasik ve TÖ-DVVT DSO sonuçları..... 29
Çizelge 4.2	KSC veri seti için TÖ-DVVT yöntemleri ile elde edilen performans artışları (klasik DVVT'ye göre)..... 30
Çizelge 4.3	Botswana veri seti için hesaplanan klasik ve TÖ-DVVT DSO sonuçları 31
Çizelge 4.4	Botswana veri seti için TÖ-DVVT yöntemleri ile elde edilen performans artışları (klasik DVVT'ye göre)..... 31
Çizelge 4.5	Pavia University veri seti için hesaplanan klasik ve TÖ-DVVT DSO sonuçları 33
Çizelge 4.6	Pavia University veri seti için TÖ-DVVT yöntemleri ile elde edilen performans artışları (klasik DVVT'ye göre) 33
Çizelge 5.1	DC Mall veri seti için hesaplanan klasik, ağırlıklı ve seçmeli sigma TÖ-DVVT DSO sonuçları 38
Çizelge 5.2	DC Mall veri seti için sigma TÖ-DVVT yöntemleri ile elde edilen performans artışları (klasik DVVT'ye göre) 39
Çizelge 5.3	DC Mall veri seti için ağırlıklı sigma TÖ (ATÖ) ve seçmeli sigma TÖ (STÖ) DVVT yöntemleri ile elde edilen performans artışları (klasik DVVT'ye göre) 39
Çizelge 5.4	Salinas valley veri seti için hesaplanan klasik, ağırlıklı ve seçmeli sigma TÖ-DVVT DSO sonuçları. 40
Çizelge 5.5	Salinas valley veri seti için sigma TÖ-DVVT yöntemleri ile elde edilen performans artışları (klasik DVVT'ye göre). 40
Çizelge 5.6	Salinas valley veri seti için ağırlıklı sigma TÖ (ATÖ) ve seçmeli sigma TÖ (STÖ) DVVT yöntemleri ile elde edilen performans artışları (klasik DVVT'ye göre) 41
Çizelge 5.7	DC Mall veri seti için farklı eğitim seti büyüklüklerine göre ağırlıklı sigma TÖ-DVVT yöntemi ile elde edilen performans artışları (klasik DVVT'ye göre) 42
Çizelge 5.8	Salinas valley veri seti için farklı eğitim seti büyüklüklerine göre ağırlıklı sigma TÖ-DVVT yöntemi ile elde edilen performans artışları (klasik DVVT'ye göre) 43
Çizelge 6.1	İkili olumsuzluk tablosu..... 46
Çizelge 6.2	Yeni farklılık metriği ile önerilen TÖ algoritması. 48

Çizelge 6.3	Salinas valley veri seti için her bir sınıf FM, tüm sınıf ortalama FM ve OSS sonuçları (L=10)	51
Çizelge 6.4	Salinas valley verisi için farklı eğitim seti büyüklüklerinde hesaplanan FM değerlerinin OSS sonuçları.....	52
Çizelge 6.5	Salinas valley verisi için farklı eğitim seti büyüklüklerinde hesaplanan DSO değerlerinin OSS sonuçları.....	52
Çizelge 6.6	Salinas valley veri seti için önerilen yöntemle FM ve DSO (%) skorlarında elde edilen performans artışları (klasik DVVT ve TSDVM'e göre)	53
Çizelge 6.7	Pavia university veri seti için her bir sınıf FM, tüm sınıf ortalama FM ve OSS sonuçları (L=10)	54
Çizelge 6.8	Pavia university verisi için farklı eğitim seti büyüklüklerinde hesaplanan FM değerlerinin OSS sonuçları.....	55
Çizelge 6.9	Pavia university verisi için farklı eğitim seti büyüklüklerinde hesaplanan DSO değerlerinin OSS sonuçları.....	55
Çizelge 6.10	Pavia university veri seti için önerilen yöntemle FM ve DSO (%) skorlarında elde edilen performans artışları (klasik DVVT ve TSDVM'e göre).	56
Çizelge 6.11	Botswana veri seti için her bir sınıf FM, tüm sınıf ortalama FM ve OSS sonuçları (L=10).	57
Çizelge 6.12	Botswana verisi için farklı eğitim seti büyüklüklerinde hesaplanan DSO değerlerinin OSS sonuçları.....	58
Çizelge 6.13	Botswana verisi için farklı eğitim seti büyüklüklerinde hesaplanan DSO değerlerinin OSS sonuçları.....	59
Çizelge 6.14	Botswana veri seti için önerilen yöntemle FM ve DSO (%) skorlarında elde edilen performans artışları (klasik DVVT ve TSDVM'e göre).....	59

**TOPLULUK ÖĞRENMELİ DESTEK VEKTÖR VERİ
TANIMLAMASI YÖNTEMİ İLE HİPERSPEKTRAL
GÖRÜNTÜLERİN SINIFLANDIRILMASI**

Faruk Şükrü USLU

Elektronik ve Haberleşme Mühendisliği Anabilim Dalı

Doktora Tezi

Tez Danışmanı: Prof. Dr. Herman SEDEF

Hiperspektral görüntüleme (HSG) son yıllarda hızla gelişen en önemli uzaktan algılama tekniklerinden birisi haline gelmiştir. HSG, malzeme ile ilgili çok büyük miktarda spektral veri elde ederek sınıflandırma, anomali ve hedef tespiti gibi birçok alanda kullanılmasını sağlar. Ancak, hiperspektral sınıflandırma ve hedef tespitinde en önemli problemlerden birisi hesaplama sürecindeki büyük miktardaki veriyi değerlendirmektir. Bu tür problemleri aşabilmek için, veri dağılımı ile ilgili herhangi bir varsayım (hesaplama) yapmaya ihtiyaç duymayan parametrik olmayan sınır betimlemeli sınıflandırma metodları tercih edilmektedir. Bu yöntemler ayrıca veriyi yüksek boyutlu özellik uzayına taşıyarak verinin doğrusal bir dağılım göstermesini sağlayan çekirdek foksasyonlarını kullanma avantajına da sahiptirler.

Sınır betimlemeli tek sınıf sınıflandırıcılar (TSS) görüntüdeki arka planla ilgili herhangi bir bilgiye sahip olunmayan hedef tespiti ve sınıflandırma problemleri için giderek daha popüler hale gelmektedir. Bu sınıflandırıcılardan birisi, Destek Vektör Makinası (DVM)'dan ilham alınarak son zamanlarda geliştirilen Destek Vektör Veri Tanımlaması (DVVT) yöntemidir. Bu yöntem, hedef sınıfa ait veriyi çevreleyen minimum hiperküre modeli oluşturur. Sınır betimlemeli TSS'lar HSG uygulamaları için çok uygun yöntemler olmalarına karşın, yalnızca hedefe ait bilgi ile az sayıda eğitim örneğinin olması performanslarının düşmesine neden olabilmektedir.

Son zamanlarda, topluluk öğrenme yöntemleri makina öğrenmesi alanında daha doğru ve kararlı sınıflandırıcıların oluşturulmasında kullanılmaktadır. Bu yöntemin amacı çoklu sınıflandırıcılar oluşturup onların tahminlerini birleştirerek nihai sonucu almaktır. Ancak, TSS'larda etkin bir topluluk öğrenme yöntemi oluşturmak hala zorlu bir konu

olarak kalmıştır. Çeşitlilik ve veri birleştirme bu yöntemde dikkate alınması gereken iki kritik konu olarak öne çıkmaktadır. Literatürde özellikle çeşitlilikle ilgili olarak, çeşitliliği yüksek olan sınıflandırıcılara sahip topluluk öğrenme yöntemlerinin sınıflandırma performansını genellikle arttığı belirtilmektedir.

Bu tezin ana amacı TSS'ların HSG sınıflandırma ve hedef tespiti performanslarının önerilecek etkili topluluk öğrenme yöntemleri ile geliştirmesidir. Ayrıca, önerilen yöntemlerle küçük örnek sayısı (KÖS) koşullarında da Hughes etkisini kaldıracak iyi sonuçların alınması hedeflenmiştir. Bu hedefleri elde etmek için, veri birleştirme safhasında kullanılan ağırlık verme ve sınıflandırıcı seçme yöntemleri önerilmiştir. Ayrıca, yeni bir çeşitlilik (farklılık) metriği önerilmiş ve sınıflandırıcılar arasındaki çeşitlilik artırılarak daha iyi bir topluluk öğrenme yöntemi oluşturulması hedeflenmiştir. Önerilen bu metrik ve metodlar farklı algılayıcılardan elde edilmiş iyi bilinen beş adet HS veri seti üzerinde uygulanmıştır. Sonuçlar farklı eğitim örnek sayıları ile klasik TSS ve bilinen çeşitlilik metrikleri ile kıyaslanmış ve analiz edilmiştir. Yapılan deneysel sonuçlar önerilen metrik ve yöntemlerin HS sınıflandırma ve hedef tespit performansını artırmak için yetenekli olduğunu ve KÖS koşullarında da oldukça iyi olduğunu göstermiştir.

Anahtar Kelimeler: Ağırlıklı oylama, çekirdek fonksiyonları, çeşitlilik, çoğunluk oylaması, destek vektör veri tanımlaması, hedef tespiti, hiperspektral görüntüleme, küçük örnek sayısı problemi, sınıflandırma, tek sınıf sınıflandırma, tek sınıf destek vektör makinası, topluluk öğrenme yöntemi, torbalama, veri birleştirme

HYPERSPECTRAL IMAGE CLASSIFICATION BASED ON ENSEMBLE SUPPORT VECTOR DATA DESCRIPTION METHOD

Faruk Şükrü USLU

Department of Electronics and Communication Engineering

PhD. Thesis

Adviser: Prof. Dr. Herman SEDEF

Hyperspectral imaging (HSI) has been a very flourishing remote sensing technique in recent years. It provides huge amount of spectral information of materials for different purposes such as anomaly, target detection and classification. However, one of the important concerns in HS classification and target detection is the huge amount of data that must be tackled in computational processing. Non-parametric boundary classification techniques are preferred methods to combat this problem, because they don't need to make any assumptions regarding the data distribution. They also have the advantage of using kernel functions which map the data in higher dimension to make the data exhibit linear patterns.

Boundary based one-class classification (OCC) has become increasingly popular for data classification and target detection problem in which there is no information of non-target (negative) data. As an OCC, support vector data description (SVDD) has recently developed method which is inspired by the support vector machine (SVM). It defines a model to construct a closed boundary around the target samples within a minimum hypersphere. Although boundary based OCCs have been shown to be more convenient in HSI applications, the performance of them can be decreased because of having only the information of target class especially in target detection problem and big data with small sample sizes (SSS).

In recent years, ensemble methods have been utilized in machine learning area to compose more accurate and stable classifiers. The idea of ensemble learning is to employ multiple classifiers and combine their predictions to get final result. However, providing efficient ensemble method for OCC has still remained as a challenging issue. Diversity and data fusion are two critical issues which has to be taken into account for

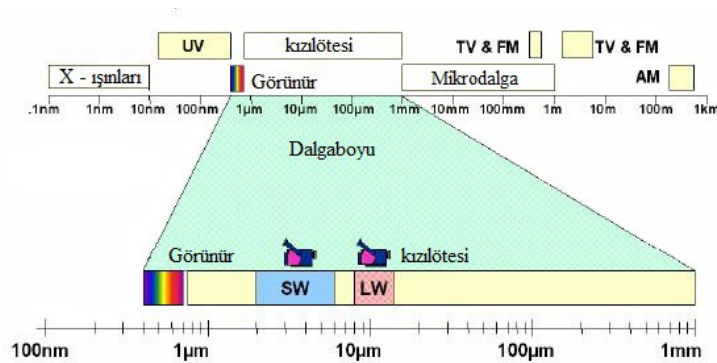
ensemble efficiency. Especially for the diversity, it is stated in the literature that having diverse classifiers is generally increases the performance of ensemble.

The major objective of this thesis is to improve OCCs' performance on HSI classification and target detection problem via proposing efficient ensemble learning techniques. We have also aim to have better results in a small training sample sizes condition to get rid of hughes effects. To achieve these aims, we have proposed new weighting and selection techniques during data fusion process. Moreover, we have offered a new diversity metric to increase diversity to get more better ensemble. Emprical studies have performed for proposed metric and methods by using five well-known hyperspectral datasets which were captured by different sensors. Comparison and analysis against single OCC and benchmarking diversity metrics (for comparison with our proposed new metric) has been done in different sample sizes. The experimental results demonstrate that the proposed metric and methods are talented for increasing performance of classification and target detection problem in HSI and very good at in condition of small sample sizes.

Keywords: Bagging, classification, data fusion, diversity, ensemble method, hyperspectral imaging, kernel functions, majority voting, one class classification, support vector data description, one class support vector machine, small sample size problem, target detection, weighted voting


1.1 Literatür Özeti

Uzaktan algılama, uydu veya hava araçları üzerlerindeki sensörler kullanılarak malzeme ile herhangi bir fiziksel temas olmadan yeryüzü üzerinde bilgi edinme yöntemidir. Bu yöntem yansıyan veya yayılan enerjinin algılanması ve kayıt edilmesi, işlenmesi, analiz edilmesi ile uygulamaya dökülmesini kapsar. Uzaktan algılayıcılar elektromanyetik spektrumun çeşitli dalga boyu bölgesinde görüntü alabilir. Hiperspektral görüntüleme (HSG) yöntemi yakın zamanda çeşitli alanlardaki uygulamalar için en ümit verici uzaktan algılama tekniklerinden biri haline gelmiştir. HSG elektromanyetik spektrumun görünür bölgesinden kızılötesi bölgesi aralığındaki farklı dalga boylarında elde edilen yüzlerce dar ve bitişik bantta malzemeden yansıyan bilgiyi toplamaktadır [1]. Spektral bantlar (Şekil 1.1) tipik olarak 10 nanometrelik nominal spektral çözünürlüğü ile genellikle elektromanyetik spektrumun 0.4-14 μm 'lik kısmında, görünür (0.4-0.7 μm), yakın kızılötesi (NIR, 0.7-1.5 μm), kısa dalgaboylu kızılötesi (SWIR, 1.5-3 μm), orta dalgaboylu kızılötesi (MWIR, 3-5 μm) ve uzun dalgaboylu kızılötesi (LWIR, 5-14 μm) kısımlarını kapsar.



Şekil 1.1 Görünür ve kızılötesi spektral bantlar

HSG her piksel için bitişik spektral bant bilgisine sahip olması sayesinde uzaktan algılama alanındaki hedef tespiti, anomali tespiti, uç eleman çıkarımı, segmentasyon ve sınıflandırma gibi birçok zor problemleri çözmek için önemli avantajlar sunar [2-4]. Arama-kurtarma operasyonları, maden tespiti, biyomedikal görüntüleme, tarımsal izleme, jeolojik keşif, derin uzay tespiti, gıda denetimi gibi sivil ve askeri birçok uygulamada kullanılmaktadır [5-7]. Şekil 1.2'de görüldüğü gibi HSG üç boyutlu (3D) bir hiperküp olarak görüntülenmekte olup burada iki boyut görüntünün uzamsal, üçüncü boyut ise spektral koordinatlarına karşılık gelir. Hem uzamsal hem de ayrıntılı spektral bilgi sayesinde, HSG hedef tespiti ve sınıflandırma problemlerinde daha yüksek doğruluğu mümkün kılacak özelliklere sahip olması gibi önemli avantajları vardır.



Şekil 1.2 Hiperspektral görüntüleme 3D hiperküp (orta resim). Bir piksele ait spektral imza ve tek dalga boyuna ait görüntü [8]

Bununla birlikte, HSG'nün yüksek boyutlu veri yapısı hesaplama karmaşıklığını artırırken özellikle örnek eğitim setinin boyutu çok düşük olduğu durumlarda Hughes olayına (boyutluluk laneti, the curse of dimensionality) neden olabilmektedir [9]. Bu nedenle, küçük örnek sayısı (KÖS)'na sahip olunan yüksek boyutlu veriler için hızlı ve doğru hesaplama yöntemleri kullanmak uzaktan algılama alanında büyük bir öneme sahip olmaktadır. Literatürde sınıflandırma problemlerinde genel olarak iki yöntem kullanılmaktadır. İlki, veri yapısını çözmek için olasılık yoğunluk fonksiyonunun tahmini ve daha sonra destek bölgesini elde etmek için eşik değerinin tanımlanması olan parametrik yöntemdir [10]. Parzen yoğunluk tahmini ve Gauss modeli bu tip yaklaşımlardır. Reed-Xiaoli (RX) algoritması Gauss modelinin en bilinen yöntemlerinden birisidir. İkincisi ise, olasılık yoğunluk fonksiyonu gibi parametreler hesaplanmadan verinin sınır bölgesine odaklanan parametrik olmayan sınır tekniği yöntemleridir. Bu yöntemler parametrik yöntemlerle karşılaştırıldığında HSG olduğu gibi yüksek boyutlu veri kümeleri için tercih edilmektedir [11]. K en yakın komşu

(kNN) tekniđi, Destek Vektör Makineleri (DVM) ve Destek Vektör Veri Tanımlama (DVVT) bu yöntem türlerinden bazılarıdır. Bu yöntemlerin parametrik olmamasının yanı sıra, sparsity (daha az eğitim örneđi yeterliliđi), iyi genelleme (her türlü veri dağılımını modellenmesi) ve çekirdek fonksiyonları kullanımı (verileri daha yüksek boyutta haritalandırması) gibi diđer avantajları da vardır [12]

Tek Sınıf Destek Vektör Makinesi (TSDVM) ve Destek Vektör Veri Tanımlama (DVVT) gibi sınır betimlemeli Tek Sınıf Sınıflandırıcı (TSS)'lar HSG sınıflandırma problemlerinde kullanılan en önemli yöntemlerdendir. Sınıflandırma problemlerinin yanı sıra hiperspektral hedef ve anomali tespitinde de bu yöntemler kullanılmaktadır. Hedef tespit probleminde yalnızca hedef sınıfa ait eğitim veri seti olduğundan bu eğitim seti ile eğitilen TSS'lar hedef sınıfa ait örnekler etrafında bir karar yüzeyini oluşturarak yeni veri setlerinin hedef sınıfa ait olup olmadığını kararını verirler [13]. Bu tezde parametrik olmayan sınır betimlemeli TSS olarak DVVT kullanılmıştır. DVVT eğitim veri setindeki hedef sınıfa ait mümkün olan en büyük sayıda veriyi çevreleyen minimum hiperküreyi bulunmaya çalışır [14]. Bu yöntem, duygusal yüz ifadesi tespiti (emotional facial expression detection), gen haritalama (gene expression), veri kümeleme (data clustering) ve kumaş kusur tespiti (fabric defect detection) gibi birçok farklı alanda kullanılmaktadır [15-17]. Son zamanlarda bu yöntem HSG ile sınıflandırma, anomali ve hedef tespiti problemlerinde tercih edilmektedir [18-20]. Klasik DVVT büyük veri kümelerinde iyi olduğu kanıtlanmış olmasına rağmen, son yıllarda DVVT başarımlarını artırmak için birçok öneri yapılmıştır. Bu çalışmalara örnek olarak, k-en yakın komşu yöntemi ile hedef veri yoğunluđu dağılımı hesaplanarak klasik DVVT tarafından tespit edilemeyebilen yüksek-yoğunluklu hedef bölgelerinin de hiperküreye içerisine alınmasını sağlayan yoğunluk ağırlıklı DVVT yöntemi önerilmiştir [21]. Le vd. yayınladıkları makalede [22], bulanık çoklu küre (Fuzzy multi-sphere) DVVT yöntemi ile tek hiperküreye ile gerçek malzeme veri örneklerini tanımlamasını garanti edemeyen geleneksel DVVT yerine bir dizi hiperküreye oluşturularak daha iyi bir veri tanımlaması önerilmiştir. Başka bir çalışmada, izafi metrik (Relevant Metric) DVVT önerilerek örnek veri setindeki benzer özelliklere yüksek ağırlıklar atanması sağlanmış ve böylece benzer verilerin daha sıkı bir arada olması sağlanarak hiperkürenin etkin (hedef sınıfa ait hemen hemen tüm verileri içermesi) tanımlanması ile performans artışı sağlanmıştır [23].

Bir diğerk önemli husus ise hiperspektral verilerin gerçek durumda lineer olarak dağılmaması nedeniyle, klasik DVVT'nin orijinal öznelik uzayında verileri doğru gösterimini sağlayamamasıdır. Bu durumda verilerin doğrusal dağılım sergilemesi için daha yüksek boyutta haritalandırılması gerekmektedir [24]. Bu işlem literatürde çekirdek numarası (kernel trick) olarak bilinen yaklaşım sayesinde çekirdek fonksiyonları ile başarılabilir. Ancak, uygun bir çekirdek fonksiyonunu ve parametrelerini seçmek çekirdek fonksiyonu temelli yöntemlerde ele alınması gereken temel problemlerden birisidir. En uygun çekirdek fonksiyonu ve parametreleri genellikle deneme yanılma yöntemi veya çapraz doğrulama yöntemi (cross-validation) ile bulunur. Bunun dışında literatürde uygun çekirdek fonksiyonu ve parametrelerini bulma çalışmalarına örnek olarak, radyal tabanlı Gauss çekirdek fonksiyon'u (RTF) için ölçek parametresinin tahmininde minimax yaklaşımı kullanılmıştır [25]. Başka bir çalışmada, RTF çekirdek fonksiyonunun parametresini seçmek için grid-search algoritmasını kullanan otomatik bir yöntem önerilmiştir [26]. Son yıllarda, yeni bir yaklaşım olarak çok çekirdekli öğrenme (ÇÇÖ, multiple kernel learning) yöntemi önerilmiştir. ÇÇÖ optimize edilmiş çekirdek fonksiyonunu elde etmek için her bir alt çekirdeğe verinin yapısına göre ağırlık veren çoklu alt çekirdeklere sahiptir [27]. Yukarıda belirtilen yöntemlerden hangileri kullanılırsa kullanılsın, en uygun çekirdek fonksiyonu ve parametrelerini seçmek genelde karmaşık ve zaman alıcı olmaktadır.

Geleneksel sınıflandırıcıların performansını artırma ve daha gürbüz hale getirmek amacıyla Topluluk Öğrenme (TÖ, ensemble) olarak adlandırılan çoklu sınıflandırıcıların kombinasyonu yöntemi ile ilgili son yıllarda önemli miktarda araştırma yapılmıştır [28]. TÖ yöntemi birden çok sınıflandırıcıyı kullanır ve her sınıflandırıcı sonuçlarını belirli füzyon kurallarına dayanarak birleştirir. Bu yöntem, biyoenformasyon, tıp, bilgi güvenliği, coğrafya, örüntü tanıma ve uzaktan algılama problemlerinde gibi çeşitli alanlarda kullanılmaktadır [29, 30]. Uzaktan algılama uygulamalarına örnek olarak; Huang ve Zhang sınıflandırma problem için, spektral, uzamsal ve semantik özellikleri hem piksel hem de nesnel düzeylerde aynı anda birleştiren DVM tabanlı çoklu evre TÖ yöntemini önermiştir [31]. Önerilen bu topluluk öğrenme temelli yöntemin vektör yığınlama DVM, çok çekirdekli DVM gibi yöntemlere göre daha doğru sınıflandırma sonuçları sağladığı gösterilmiştir. Başka bir makalede, yüksek çözünürlüklü görüntülerde büyük depolama ve hesaplama maliyeti ile başa çıkabilmek için topluluk öğrenmesinin özel bir durumu olan çok çekirdekli DVM'e

dayanan çoklu indeks öğrenme yöntemi önerilmiştir [32]. Kang vd. yaptıkları çalışmada [33], çok sınıflı sınıflandırma amacıyla farklı tip tek sınıf sınıflandırıcıların bir araya getirilmesi şeklinde önerilen TÖ yöntemi önermiş ve klasik tek sınıf sınıflandırma algoritmalarından daha iyi olduğunu göstermiştir. Başka bir makalede, SVM temelli alaka geri bildirimlerinin sonuçlarının karmaşıklığını ve uygunsuzluğunu çözmek için aktif DVM tabanlı çoklu sınıflandırıcı yöntemi önerilmiştir [34]. Topluluk öğrenmeli bu yöntemin eğitim veri setinin küçük olduğu durumlarda birçok diğer klasik sınıflandırıcıdan daha iyi performans gösterdiği ispat edilmiştir. Kang vd. büyük ölçekli tıbbi veri setleri üzerinde DVM'ndeki yüksek eğitim süresinin üstesinden gelmek için etkili bir TÖ yöntemi önermiştir [35]. Bu çalışmadaki deneysel sonuçlar incelendiğinde önerilen TÖ yöntemlerin geleneksel DVM sınıflandırıcısına kıyasla daha az eğitim süresi ve daha güvenilir tahmin sonuçları çıkardığı gözlemlenmiştir. Ancak DVM gibi çok sınıflı sınıflandırıcı için birçok TÖ yöntemi çalışmaları olmasına rağmen, TSS'lar için bu yöntem uygulamaları literatürde oldukça azdır. TSS sınıflandırma veya hedef tespiti problemlerinde yalnızca hedef sınıf bilgisine sahip olması nedeniyle yetkin bir topluluk öğrenmeli TSS oluşturulması çok sınıflı sınıflandırıcılara nazaran daha zor ve sınırlıdır [36]. Yapılan literatür taramasında TSS olan DVVT ile yapılan topluluk öğrenmeli uygulamaların az olduğu gözlemlenmiştir. Kısıtlı olan çalışmalara örnek olarak; Tai ve Wang yayınladıkları makalede [37], ılgın bitkisinin bölgesel ölçekte dağılımını haritalandırma probleminde belirsizliği nicelleştirmek ve kullanıcı doğruluğunu arttırmak için topluluk öğrenmeli DVVT yöntemi önerilmiştir. Başka bir makalede, sentetik veri setleri üzerinde, klasik DVVT'nin sonuçlarını iyileştirmek için yeni bir yöntem olarak korentropi (correntropy) temelli seçmeli TÖ yöntemi önerilmiştir [38].

Etkin ve gürbüz bir TÖ yöntemi oluşturmak için bilinmesi gereken kritik konulardan biri, etkili ve doğru bir veri birleştirme (kombinasyon) tekniği oluşturmaktır. Temel uygulanan birleştirme yöntemleri arasında en yaygın, basit ve gürbüz yöntem çoğunluk oylaması (ÇO) yöntemi olup özellikle sınıflandırıcıların çıktıları direkt sınıf etiketleri (hard label) olduğu durumlarda kullanılmaktadır [39]. Doğru veri birleştirme tekniğini seçmenin yanı sıra, daha doğru ve etkili bir TÖ elde etmek için bir başka ana konu da topluluk öğrenmede kullanılan her bir taban sınıflandırıcıları arasında mümkün olduğunca çeşitliliği (Diversity) arttırmaktır. Çeşitlilik (negatif bağımlılık, bağımsızlık, ortogonalite ve tamamlayıcılık), taban sınıflandırıcıların örnek verinin

tanımlamasındaki göstermiş olduğu farklılık seviyesini ve ilişkisiz hataları temsil eder [40]. Literatürde, TÖ'de herhangi bir iyileşme sağlamak için teorik olarak sınıflandırıcılar arasında çeşitlilik olması gerektiği değerlendirilmektedir. Eğer sınıflandırıcılar arasında çeşitlilik yoksa (benzer iseler) bu sınıflandırıcıların sonuçlarını birleştirerek hiçbir gelişme elde edemeyebiliriz [41]. TÖ yönteminde çeşitliliğin önemi ve uygulamaları ile ilgili birçok yayın bulunmaktadır. Kuncchava, TÖ'de sınıflandırıcıların birleştirmenin başarısı için çeşitliliğin önemli bir unsur olduğunu belirtmiştir [42]. Tumer vd. yaptığı çalışmada [43], özellikle eğitim verisinin sınırlı olduğu durumlarda taban sınıflandırıcılar arasındaki çeşitliliğin artırılmasının faydalarını gösterilmiştir. HSG'de uygulanan topluluk öğrenmede çeşitliliğin önemini vurgulayan çalışmalarda örnek olarak; Chen vd., HSG üzerinde daha iyi bir doğruluk elde etmek için topluluk öğrenmeli alt uzay DVM yöntemi önermiş ve bireysel sınıflandırıcılar arasındaki çeşitliliğin önemini göstermiştir [44]. Döndürme Ormanı (DO, Rotation Forest) adı verilen bir başka TÖ yöntemi hiperspektral görüntülerin sınıflandırılmasında hem temel sınıflandırıcıların doğruluğunu hem de topluluktaki çeşitliliği artırmak için önerilmiş ve topluluk içindeki oluşturulan yüksek çeşitliliğin genellikle yüksek doğrulukla sonuçlandığı gösterilmiştir [45].

Bununla birlikte, sözkonusu bu yöntemde sınıflandırıcılar arasında çeşitlilik oluşturmanın her zaman faydalı olduğu cevabı net olarak verilemeyen açık bir sorudur. Kunccheva ve Whitaker, bazı özel durumlarda çeşitlilik ve doğruluk arasında ka nıtlanmış bağlantılar olmasına karşın, gerçek örüntü tanıma problemlerinde çeşitliliğin herhangi bir pratik değere sahip olup olmadığının belirsiz olduğunu vurgulamıştır [46]. Ayrıca Kunccheva, gerçek veri setleri (UCI veri setleri) üzerinde çeşitlilik ile ilgili simülasyonlar uygulamış, bu uygulamalarda da çeşitliliğin beklendiği kadar büyük bir rol oynamadığını belirtmiştir [47]. Başka bir çalışmada, bazı durumlarda topluluk öğrenmede orta derecede çeşitlilik oluşturmanın yüksek çeşitlilik oluşturmaya göre daha iyi sonuçlar ürettiği gösterilmiştir [48]. Bununla birlikte, literatürde sınıflandırıcılar arasında çeşitliliğin artırılması ile TÖ yöntemi performansının iyileştirdiği konusunda genel fikir birliğine varılmıştır.

1.2 Tezin Amacı

HSG sınıflandırma ve hedef tespit problemlerinde yalnızca hedef sınıfa ait bilgiye ve sınırlı sayıda eğitim örneklerine sahip olunması durumunda tek sınıf sınıflandırıcılarda

başarım performansını artırmak için etkin bir topluluk öğrenme yöntemi uygulaması sınırlı ve zor olabilmektedir. TÖ yöntemlerinde daha doğru ve kararlı sonuçlar elde etmek için ortaya çıkan kritik konular şu şekilde özetlenebilir:

- Taban sınıflandırıcıları arasında çeşitliliği artıracak teknikler geliştirmek,
- Her bir taban sınıflandırıcıya uygun ağırlık verilerek etkin bir birleştirme tekniği uygulamak,
- Birleştirme sürecinde tüm taban sınıflandırıcı sonuçlarını kullanmak yerine sınıflandırıcılardan daha değerli olanları seçmek ve sadece seçilenleri birleştirmek.

Diğer kritik konu ise, HSG gibi yüksek boyutlu verilerde veri setinin büyüklüğüne oranla küçük eğitim örneği sayısına sahip olma problemidir. Bu olay literatürde "*Boyutsallık laneti*" (curse of dimensionality) veya "*Hughes olayı*" (Hughes phenomenon) ile tanımlanır. Hughes olayı, belirli sayıda sabit eğitim örneği ile spektral bant veya boyut sayısının artmasıyla tahmin doğruluğunun azalmasıdır [49].

Bu tez kapsamında, HSG sınıflandırmasında ve hedef tespiti probleminde başarımlarını artırımı için etkin ve gübüz TÖ algoritmaları geliştirilmesi amaçlanmıştır. Bu algoritmaları geliştirmek için aşağıda verilen hususlar göz önüne alınmıştır.

- Taban sınıflandırıcıları arasındaki farklılığı ölçen yeni bir benzerlik (farklılık) metriği önermek ve birleştirme safhası öncesi çeşitliliği artırmak,
- Yeni ağırlıklandırma ve seçme yöntemleri önererek etkin veri birleştirmesi oluşturarak daha doğru ve kararlı sonuçlar elde etmek,
- Çok küçük eğitim örneği boyutunda bile daha iyi sonuçlar almak.

1.3 Hipotez

Sonuç olarak, her sınıflandırıcı arasında uygun bir ağırlık ve çeşitlilik içeren kombinasyon tekniği tasarlayan algoritmalar üretilerek, HSG'lerde sınıflandırma ve hedef tespiti problemlerinde küçük boyutta eğitim örneği koşullarında bile performans iyileştirmesi yapılabilmesi hedeflenmiştir. Bu tez çalışmasında altı konu üzerinde yoğunlaşmıştır.

- Ağırlıksız ve ağırlıklandırılmış kombinasyon yöntemleri ile TÖ yaklaşımı tasarlamak.

- Sınıflandırıcı çekirdek fonksiyon parametrelerini ayarlamaya ihtiyaç duymayan topluluk öğrenme tekniğinden esinlenen yeni bir yöntem tasarlamak.
- Her bir sınıflandırıcı için uygun ağırlığı tanımlamak için ağırlık atama tekniği ve daha fazla performans kazancı elde etmek için sınıflandırıcı seçim yöntemi önermek.
- TÖ yönteminde sınıflandırıcılar arasında çeşitliliği artırmak için yeni bir benzerlik metriği önermek.
- HS verilerde hem sınıflandırma hem de hedef tespiti problemlerinde daha doğru ve istikrarlı sonuçlar elde etmek için önerilen algoritmalara yönelik karşılaştırmalı çalışma ve analiz yapmak.
- Ayrıca önerilen yöntemlerin Hughes olayı için çözüm olduklarını göstermek.

TEORİK ALTYAPI


2.1 Sınır Betimlemeli Tek Sınıf Sınıflandırıcılar (TSS)

Sınır Betimlemeli TSS'lar karar verme yüzeyini oluşturmak için hedef verilerin sınır noktalarına odaklanırlar. Bu yöntemler hedef sınıfın bilgisinin mevcut olduğu ve bunun dışındaki arka plan (diğer sınıflar) hakkında hiçbir şey bilinmediği durumlarda kullanışlıdır. Belirlenen sınır bölgesi içerisinde kalan yeni örnekler hedef nesnelere olarak ve geriye kalan diğer tüm örnekler ise aykırı nokta (outlier) olarak belirlenir [11]. Bu yöntemler, sinyal işleme, örüntü tanıma, tıbbi tanı ve sahtekarlık algılama gibi birçok araştırma alanında yaygın olarak kullanılmaktadır. Ayrıca HSG gibi yüksek boyutlu veriler için olasılık yoğunluğu hesaplayan parametrik yöntemlerden daha verimli olduğu gösterilmiştir [50,51]. Bu yöntemler, HSG uygulamalarında hem sınıflandırma hem de hedef tespiti problemleri için literatürde yaygın olarak kullanılmaktadırlar. Tek sınıf problemlerinde, hedef sınıf için "1" ve hedef olmayan diğer sınıflar (outlier) için "-1" olmak üzere iki sınıf etiketi vardır. Bu yöntemlere örnek olarak, yaygın olarak kullanılan Tek Sınıf Destek Vektör Makinası (TSDVM) ve tezde ana sınıflandırıcı olarak kullandığımız Destek Vektör Veri Tanımlaması (DVVT) yöntemleri söylenebilir.

2.1.1 Destek Vektör Veri Tanımlaması (DVVT)

Tax ve Duin tarafından önerilen DVVT sınır betimlemeli TSS'dir [14]. Bu yöntem iki sınıflı problemlerde kullanılan DVM'den esinlenmiştir. DVVT'nin amacı, hedef verisinin etrafında minimum kapalı hiperküre sınırı oluşturmaktır. Küre merkez, a , ve yarıçap, R ile tanımlanır (Şekil 2.1). Küreyi oluşturma esnasında, yarıçapı (R)

küçültülerek kürenin hacmini en aza indirgemeye çalışılırken hedef sınıfa ait eğitim verilerin hepsinin ya da neredeyse tamamının kürenin içinde olması hedeflenir.



Şekil 2.1 Hedef sınıfı içeren merkez, a ve yarıçap, R ile tanımlanmış hiperküreye

DVVT verilen bir dizi eğitim örneği ile $\{X_i, i = 1, \dots, N\}$ hata fonksiyonunu en aza indirirken,

$$\min \mathcal{E}(R, a, \xi_i) = R^2 + C \sum_i \xi_i \quad (2.1)$$

şağıdaki kısıtları elde etmeye çalışılır,

$$\|x_i - a\|^2 \leq R^2 + \xi_i, \quad \xi_i \geq 0 \quad (2.2)$$

Burada, ξ_i karar sınırını rahatlatmak için yumuşak bir marj olan gevşeklik değişkeni (slack variables) ve C kürenin ödünleşimini (trade-off) ve reddedilen hedef nesne sayısını kontrol eden cezalandırma faktörüdür (punish factor) [20]. Yukarıdaki optimizasyon problemi Lagrange çarpanı metodu ile çözülebilir.

$$L(R, a, \xi_i, \gamma_i, \alpha_i) =$$

$$R^2 + C \sum_i \xi_i - \sum_i \alpha_i \{R^2 + \xi_i - (\|x_i\|^2 - 2a \cdot x_i + \|a\|^2)\} - \sum_i \gamma_i \xi_i \quad (2.3)$$


L 'yi R ve a 'ya göre kısmi türevlerini alır ve bunları sifira eşitlersek, aşağıdaki eşitlikleri buluruz,

$$\sum_i \alpha_i = 1, \quad a = \sum_i \alpha_i \cdot x_i \quad (2.4)$$

Burada, $\alpha_i \neq 0$ olan her eğitim örneği küre sınırında uzanan destek vektörleri olarak adlandırılır. Hiperküreye oluşturulduktan sonra, herbir test örneği y_i için aşağıda verilen karar verme fonksiyonu kullanılarak etiketlendirme yapılır.

$$f(y) = \text{sign}(R^2 - \|y - a\|^2) \quad (2.5)$$

göstermesi sağlanır (Şekil 2.3). Öznitelik haritalaması çok yüksek boyutlu ve işlenmesi oldukça karmaşık olabilir. Ancak işlemleri kolaylaştırmak için, "çekirdek hilesi" (kernel trick) yardımıyla içsel çarpımlar mercer teoremini [54] karşılayacak şekilde çekirdek fonksiyonu $\mathbf{K}(x_i, x_j) = \langle \phi(x_i), \phi(x_j) \rangle$ ile değiştirilir.



Şekil 2.3 Doğrusal dağılım elde etmek için haritalama yaklaşımı örneği

Çekirdek fonksiyonu kullanıldığında, DVVT için karar fonksiyonu,

$$f(y) = \text{sign} \left\{ R^2 - \left(\mathbf{K}(y, y) - 2 \sum_i \alpha_i \mathbf{K}(y, x_i) + \sum_{i,j} \alpha_i \alpha_j \mathbf{K}(x_i, x_j) \right) \right\} \quad (2.9)$$

TSDVM için ise,

$$f(y) = \text{sign} \left(\sum_i \alpha_i \mathbf{K}(y, x_i) - \rho \right) \quad (2.10)$$

Literatürde, doğrusal, polinom, radyal tabanlı gauss fonksiyonu (RTF), laplace gibi farklı çekirdek fonksiyonları kullanılmaktadır. Bu çalışmada, makine öğrenmesinde en yaygın olarak kullanılan RTF çekirdek fonksiyonu kullanılmıştır. RTF'nun matematiksel ifadesi,

$$\mathbf{K}(x_i, x_j) = \exp \left(-\frac{\|x_i - x_j\|^2}{\sigma^2} \right) \quad (2.11)$$

RTF fonksiyonun ana ve önemli parametresi olan sigma (σ), sınır sıklılığını kontrol altına almaya yarayan optimize edilmesi gereken hassas bir parametredir. Çok küçük sigma değerleri için, tüm örnek nesnelere destek vektörleri haline gelir ve aşırı uygunluk (overfitting) oluşur. Bu durum DVVT'nin genelleme özelliğini kaybetmesine ve öngörü gücünün düşmesine neden olur. Çok büyük sigma değerleri için ise, destek vektörler oldukça az olur ve yetersiz uyum (underfitting) oluşur. Bu durum DVVT'nin orijinal küresel şekilli çözüme yaklaşması ve olası önemsiz karar sınırını oluşturması ile zayıf

performansa neden olur [12]. Bu nedenle, RTF için uygun çekirdek parametresini (σ) seçmek kritik konulardan biri haline gelmektedir.

2.2 Topluluk Öğrenme Yöntemi

Topluluk öğrenme yöntemleri, nihai kararı vermek için bir grup sınıflandırıcının bireysel kararlarını belirli bir füzyon kurallarına göre paralel veya ardışık olarak birleştiren istatistiksel bir tekniktir. Bu yöntemler sınıflandırıcıların tahmin performanslarını arttırmakla kalmayıp aynı zamanda gürbüzlüğünde geliştirir [55]. Kemoinformatik, biyoinformatik, finans, bilgi güvenliği, tıp, imalat, coğrafya ve görüntü işleme gibi pek çok alanda çeşitli TÖ teknikleri kullanılmaktadır [56-61]. TÖ yöntemleri oluşturma fikri uzun süredir araştırılan bir konudur. Bu yöntem ilk defa 1977 yılında Tukey tarafından iki doğrusal regresyon modelinin daha iyi sonuçlar elde etmek için birleştirilmesi ile önerilmiştir [62]. Ancak, TÖ yönteminde ana akım 1990'ların başında başlamıştır. Hansen ve Salamon, tek bir yapay sinir ağının (YSA) performansını artırmak için benzer şekilde yapılandırılmış YSA'larının topluluk öğrenmesini önermiştir [63]. Schapire, bir grup zayıf öğrenme algoritmalarını birleştirerek yüksek doğruluğu elde eden bir algoritmaya dönüştürmek için Hızlandırma (Boosting) algoritmasını önermiştir [64]. Wolpert tarafından genelleme hata oranını en aza indirmek için bir veya daha fazla genellemeden oluşan yığılmış genelleme (Stacked generalization) yöntemi uygulanmıştır [65]. Freund ve Schapire, hızlandırma yöntemini geliştirmiş ve sınıflandırıcının ağırlıklı kombinasyonunu kullanan ayarlanabilir hızlandırma (AdaBoost) yöntemini önermiştir [66]. Breiman, her bir taban sınıflandırıcı için orijinal eğitim veri setinden rasgele örneklemeyle dayanan yeni bir eğitim veri seti oluşturmaya dayanan torbalama (bagging) yöntemi geliştirmiştir [67]. Rasgele altuzay (random subspace) yöntemi Ho tarafından önerilmiş olup bu yöntem taban sınıflandırıcıların orijinal öznitelik uzayından seçilen altöznitelik kümeleri ile eğitildiği ve daha sonrada birleştirildi bir model olarak karşımıza çıkmaktadır [68]. Bir başka TÖ tekniği olarak döndürme ormanı (rotation forest) öznitelik çıkarımına dayanan bir yöntem olarak sunulmuştur [69]. Literatürde, dört farklı kategoride/seviyede uygulanan çeşitli topluluk öğrenme yöntemleri kullanılmaktadır [70].

Veri Seviyesi: Orijinal eğitim veri setinden yeniden örnekleme ile elde edilen farklı eğitim setlerinin aynı tip taban sınıflandırıcılara verilmesi ve sınıflandırma sonuçlarının

nihai karar için birleştirilmesidir. Torbalama ve hızlandırma bu tür TÖ yöntemlerindedir.

Öznitelik Seviyesi: Orijinal öznitelik uzayından rastgele seçilen farklı öznitelik altkümelerinin taban sınıflandırıcılara verilmesi ve sınıflandırma sonuçlarının nihai karar için birleştirilmesidir. Rasgele altuzay ve Döndürme Ormanı bu yöntem türlerindedir.

Sınıflandırıcı Seviyesi: Farklı sınıflandırıcıların aynı eğitim veri setleri kullanılarak eğitilmesi ve nihai sınıflandırma sonuçlarını elde etmek için sonuçların birleştirilmesidir. Örnek olarak Li tarafından, tek sınıf sınıflandırıcı olan DVVT ile iki sınıf sınıflandırıcı olan DVM sonuçları birleştirilmesi ile 1.5-DVM olarak adlandırılan TÖ yöntemi önerilmiştir [70].

Karar Seviyesi: Taban sınıflandırıcıların çıkış türüne göre (katı seviye (hard level) ve yumuşak seviye (soft level)) farklı veri birleştirme stratejileri oluşturulmuştur. Katı seviye etiketleme her bir test örneğinin nihai sınıf etiketini belirlerken, yumuşak seviye ise her bir test örneğinin sınıflandırıcı tarafından sınıflandırma olasılığının tahminidir. Çoğunluk oylaması ve ağırlıklı oylama katı seviye birleştirme yöntemlerinden, maksimum, minimum, medyan, toplam, çarpım yumuşak seviye birleştirme yöntemlerinden bazılarıdır.

TÖ yöntemleri yalnızca performansı arttırmak için değil aynı zamanda sınıflandırıcıların gürbüzlüğü artırmak için de kullanılabilir. Bu yöntemin uygulanması için aşağıda verilen üç ana neden belirtilebilir [55];

- Yetersiz eğitim verisi (Küçük örnek sayısı),
- Kararsız öğrenme algoritması,
- Öznitelik uzayında gerçek hedef fonksiyonunu içermeyebilmesi.

Etkin ve gürbüz bir topluluk öğrenme yönetimi oluşturmak için iki kritik husus vardır;

- Tüm taban sınıflandırıcılar arasındaki çeşitlilik (diversity),
- Uygun kombinasyon (veri füzyonu) tekniği.

2.2.1 Çeşitlilik (Diversity)

TÖ yöntemindeki çeşitlilik, her bir taban sınıflandırıcının genelleme hatalarının mümkün olduğunca ilişkisiz olmasıdır [40]. Teorik olarak, eğer her bir sınıflandırıcı

diğerlerinden bağımsız sonuçlar üretebiliyorsa TÖ tekniği performansı genellikle artar. Eğer tüm taban sınıflandırıcılar kümesi özdeşse herhangi bir kazanç veya avantaj elde edilemez. Bu nedenle, taban sınıflandırıcılar arasında belirli bir oranda çeşitlilik oluşturulmalıdır. Yüksek miktarda çeşitliliğin TÖ metodu için her zaman yararlı olduğu hala net değildir. Bununla birlikte, araştırmacılar arasında daha iyi bir TÖ yöntemi için en önemli unsurun sınıflandırıcılardaki çeşitlilik olduğu ve ikincil olarakta kombinasyon yönteminin olduğu konusunda fikir birliği sağlanmıştır [71].

Topluluk öğrenme yönteminde çeşitlilik örtülü (implicitly) ve direkt (explicitly) oluşturulabilir [72]. Örtülü tarzda çeşitlilik aşağıdaki verilen uygulamalarla yapılabilir,

- Torbalama yönteminde olduğu gibi farklı (rasgele seçilmiş) eğitim setleri kullanmak,
- Döndürme Ormanı yönteminde olduğu gibi öznitelik alt kümeleri oluşturmak,
- Farklı tip sınıflandırıcılar seçmek.

Çeşitliliği direkt olarak, optimize edilmiş benzerlik metriği tanımlama ve onu her sınıflandırıcıya ağırlık verme yöntemi ile oluşturulabilir. Bununla birlikte, mantıklı ve gürbüz bir çeşitlilik ölçütü oluşturmak/bulmak oldukça zordur. Yüzyılı aşan bir süreden beri farklı alanlarda en anlamlı benzerlik (similarity) veya farklılık (dissimilarity) metriği (ölçütü) önermek için birçok araştırma yapılmaktadır. Bazı metrikler Yule-Q istatistiği gibi doğrudan istatistik disiplini ile ilişkili olsalar da, bazıları ekolojik türlerin kümeleneğinde kullanılan jaccard [73] ve yazılım hatası analizinde kullanılan tarantula metriği [74] gibi spesifik alan/amaç için geliştirilmiştir.

Benzerlik veya farklılık metrikleri çeşitli alanlarda farklı amaçlar için kullanılmaktadır. Örneğin, biyoinformatikte gen çiftleri, gen ürünleri ve protein fonksiyonu tahminleri arasındaki ilişkiyi araştırmada, kemoinformatikte ilaç geliştirmede, etnolojide farklı halkların özelliklerini karşılaştırmak, analiz etmek ve bunların arasındaki ilişkiyi keşfetmekte, veri madenciliğinde anormalliği tespit etmek ve veri tabanlarından yararlı bilgiler elde etmekte, taksonomide restorasyonda ilgili ölçütlere dayalı varlıkların tanımlanması ve sınıflandırılmasında, görüntü işlemede görüntü alımı, kodlama, iyileştirme ve restorasyonda kullanılmıştır [75-78]. Örüntü tanıma alanında da, yüz tanıma, kelime farklılığı algılama, boyutsal azaltma ve HSG sınıflandırması gibi amaçlarla uygulanmıştır [2, 79-80]. Kullanıldıkları amaç ne olursa olsun tüm benzerlik veya farklılık metriklerini iki kategoriye ayrılmaktadır [81].

İkili Olmayan (Non-pairwise) Ölçüm Metrikleri: Tüm taban sınıflandırıcılarını topluca birkerede değerlendiren ölçütlerdir. Kohavi-Wolpert varyansı, entropi ölçümü, zorluk ölçümü bunlardan bazılarıdır.

İkili (Pairwise) Ölçüm Metrikleri: İkili olmayan yöntemlere göre uygulaması daha basit ve çoğunlukla tercih edilen ölçütlerdir [42]. İkili ölçüm yönteminde, tüm taban sınıflandırıcı arasındaki olası çiftler kullanılarak ikili ölçümler hesaplanıp ortalaması alınarak çeşitlilik ölçümü bulunur. Bir TÖ'de M taban sınıflandırıcıları için, $M(M - 1)/2$ ikili çeşitlilik ölçümleri hesaplanır ve daha sonra ortalamaları alınarak nihai çeşitlilik ölçüsü elde edilir. Jaccard, Q-İstatistiği, korelasyon katsayısı, kappa, tarantula metrikleri bu bu tip ölçütlerdendir.

İkili ölçüm metrikleri için iki sınıflandırıcı çıktısını f_i ve f_j olarak kabul edersek, sınıflandırıcı sonuçlarının olumsuzluk (contingency) tablosu Çizelge 2.1'de verildiği gibi olacaktır. Çizelgedeki değişkenler, tek sınıf sınıflandırma sonucunda hedef (pozitif)/hedef olmayan (negatif) çıktılarla ilgili çiftlere ait durumlarını göstermektedir.

Çizelge 2.1 İki sınıflandırıcının olumsuzluk tablosu

		f_j		Toplam
		Pozitif (1)	Negatif (-1)	
f_i	Pozitif (1)	a	b	a+b
	Negatif (-1)	c	d	c+d
	Toplam	a+c	b+d	N=a+b+c+d

Literatürde çeşitli alanlarda farklı amaçlarla kullanılan yüze yakın benzerlik veya farklılık metriği bulunmaktadır. Jaccard, Q istatistiği, çift arıza (Double-fault) ve basit eşleme (Simple matching) yaygın kullanılan yöntemler olup bu tezde önerdiğimiz yeni metriğe karşı karşılaştırma (benchmarking) metrikleri olarak kullanılmıştır. Bu metriklere ait kısa açıklama ve olumsuzluk tablosuna göre formülasyonu aşağıda verilmiştir.

Jaccard: Özellikle veri kümeleme alanında olmak üzere birçok alanda yaygın olarak kullanılan benzerlik ölçüsüdür [73]. Olumsuzluk tablosuna göre matematiksel formülü,

$$S_{jaccard} = \frac{a}{a + b + c} \quad (2.12)$$

Q İstatistiği: İstatistikte Yule tarafından benzerlik ölçütü olarak önerilmiştir [82]. Kuncheva tarafından TÖ yönteminde sınıflandırıcılar arasındaki çeşitliliği ölçmek için kullanılmıştır [81]. Olumsuzluk tablosuna göre matematiksel formülü,

$$S_Q = \frac{ad - bc}{ad + bc} \quad (2.13)$$

Çift-Arıza (ÇA, Double-Fault): Literatürde yaygın olarak kullanılmaktadır. Giacinto ve Roli tarafından görüntü sınıflandırmasında TÖ yöntemi için farklılık ölçütü olarak kullanılmıştır [83]. Olumsuzluk tablosuna göre matematiksel formülü,

$$D_{DF} = \frac{d}{N} \quad (2.14)$$

Basit Eşleme (BE, Simple Matching): Sokal ve Michener tarafından benzerlik metriği olarak önerilmiştir [84]. Farklılık biçimi anlaşmazlık ölçüsü (disagreement measure) olarak adlandırılır. Olumsuzluk tablosuna göre matematiksel formülü,

$$S_{SM} = \frac{a + d}{N} \quad (2.15)$$

Kuncheva tarafından, ÇA ve BE metriklerinin sınıflandırıcı TÖ performansına çeşitlilik ölçütleri olarak katkı sağladığı tespit edilmiştir [41].

2.2.2 Birleştirme Yöntemleri ve Oylama

Topluluk öğrenme yöntemlerinde daha doğru sonuçlar elde etmek için bir diğer önemli husus, taban sınıflandırıcıların çıktılarını birleştirmek için uygun veri füzyon (birleştirme) tekniğini seçmektir. Birleştirme fonksiyonu genel doğruluğu artırmak için her bir taban sınıflandırıcıyı en uygun yöntemle birleştirmekten sorumludur. İstatistik, örüntü tanıma ve makine öğrenmesinde çoğunluk oylaması (majority voting), maksimum, minimum, ortalama, çarpım, naive bayes ve karar şablonları (decision templates) gibi birçok farklı birleştirme teknikleri vardır. Çoğunluk oylaması (ÇO) ve ağırlıklı oylama (AO) özellikle sınıflandırıcı çıktıları katı (sınıf) seviye etiketler olduğunda en sık kullanılan, kolay uygulanabilir ve gürbüz kombinasyon yöntemlerindedir. Ayrıca bu yöntemlerde taban sınıflandırıcılar eğitildikten sonra herhangi bir parametre ayarı ve ek bilgiye ihtiyaç duyulmaz [39]. ÇO, sınıflandırıcılar arasında en fazla oyu alan sınıf etiketinin seçilmesi yöntemidir. Her bir taban TSS'dan alınan test örneği için sınıf etiketi aşağıdaki gibi gösterilirse,

$$f_{i,TSS} \rightarrow \{-1 \text{ (hedef değil)}, 1 \text{ (hedef)}\} \quad (2.16)$$

ÇO'da her bir piksel için etikelerin yarısından fazlasına sahip olan etiket değeri sınıf etiketi olarak atanmaktadır. Matematiksel olarak aşağıdaki şekilde yazılabilir,

$$f_{i,\zeta o} = \begin{cases} -1, & \frac{1}{M} \sum_{k=1}^M f_{i,TSS} < 0 \\ 1, & \frac{1}{M} \sum_{i=1}^M f_{i,TSS} \geq 0 \end{cases} \quad (2.17)$$

Basit ÇO'da her bir seçmenin aynı ağırlığı vardır. Eğer uygulanan TÖ yönteminde sınıflandırıcıların aynı doğruluğa sahip olmadığı biliniyorsa, daha doğru karar veren sınıflandırıcının nihai karar üzerindeki etkisini artırmak amacıyla ağırlık (w_i) verilerek ÇO ile elde edilen performans daha fazla arttırabilir. Buradaki kritik konu veri birleştirmeden önce her taban sınıflandırıcıya en optimum ve uygun ağırlıkları sağlamaktır. Ağırlıklı oylamada nihai karar aşağıdaki şekilde hesaplanır,

$$f_{i,ao} = \begin{cases} -1, & \frac{1}{M} \sum_{k=1}^M w_i f_{i,TSS} < 0 \\ 1, & \frac{1}{M} \sum_{k=1}^M w_i f_{i,TSS} \geq 0 \end{cases} \quad (2.18)$$

Her iki formülasyondaki f_i değerlendirilen yeni verinin nihai karar etiketi, w_i her bir sınıflandırıcı sonucuna atanan ağırlık ve M topluluk öğrenmedeki kullanılan sınıflandırıcı sayısıdır.

Genellikle taban sınıflandırıcısının ağırlıkları sınıflandırma doğrulukları ile orantılı olarak verilir [85]. Ağırlıkları elde etmek için optimizasyon yöntemleri ve sezgisel yaklaşımlar da kullanılır. Bu tezde, önerdiğimiz yeni benzerlik metriği, sınıflandırıcı performansı ölçmede kullanılan dengeli sınıflandırma oranı (DSO) ve korelasyon katsayısı ölçütlerini ağırlıkları atamak için kullanılmıştır.

2.2.3 Torbalama

Torbalama (Bagging: **B**ootstrap **a**ggregating) Breiman tarafından önerilmiş olup en yaygın, güçlü ve kolay uygulanabilir TÖ yöntemlerinden biridir [67]. Bu teknikte tekrar yerine koyma ile rastgele örnekleme dayanan önyükleme (bootstrapping) yaklaşımı kullanır.

Elimizdeki orjinal eğitim veri seti $S = \{x_i, i = 1, \dots, N\}$ olmak üzere, torbalama tekniğinde M defa çoğaltılmış eğitim veri setleri $\{S_m, m = 1 \dots M\}$ oluşturulur. Her çoğaltılan eğitim veri seti genellikle orijinal eğitim setiyle aynı boyutlara sahip olsa da,

orijinal veri boyutundan daha küçük olarakta seçilebilir. Böylece çoğaltılan eğitim veri seti boyutu $N^* \leq N$ olabilir. Torbalama özellikle yüksek boyutlu veri kümelerinde kritik olan küçük örnek eğitim sayısı nedeniyle kararsız olan sınıflandırıcıları daha kararlı hale getirmek için etkili bir yöntem olarak uygulanmıştır [36]. Torbalama yönteminin bu özelliği, örnek veri setinin sınırlı olması nedeniyle HSG ile sınıflandırma ve hedef tespit uygulamalarında bu yöntemi en uygun aday TÖ tekniklerinden biri haline getirmektedir.




HİPERSPEKTRAL VERİ SETLERİ VE PERFORMANS DEĞERLENDİRME ÖLÇÜTLERİ

3.1 Hiperspektral Veri Setleri

Bu tezde, deneysel uygulama, karşılaştırma ve analiz için kesin referans bilgisine (groundtruth) sahip beş gerçek ve iyi bilinen hiperspektral veri seti kullanılmıştır. Bu veri setleri dört farklı uzaktan algılama sensörü tarafından elde edilmiştir: NASA Airborne Visible/Infrared Imaging Spectrometer (AVIRIS), Reflective Optics System Imaging Spectrometer (ROSIS), Hyperspectral Digital Imagery Collection Experiment (HYDICE) and NASA Hyperion sensor. veri setleri için ayrıntılı bilgi aşağıda verilmiştir.

3.1.1 Kennedy Space Center (KSC) Veri Seti


23 Mart 1996'da Florida'daki Kennedy Uzay Merkezi üzerinden elde edilen NASA AVIRIS verisidir. 18 metrelik uzamsal çözünürlüğü ile görünür ve yakın kızılötesi spektrumunda (400-2500 nm) 10 nm genişlikte 224 bant içermektedir. Bu alanın görüntü (uzamsal) boyutu 512×614 pikseldir. Su buharı soğurma bantları ve gürültülü bantları çıkardıktan sonra toplam 176 banttan oluşan veri elde edilmiştir. 13 adet sulak ve dağlık alan sınıfını olan HS verisinin RGB görüntüsü ve kesin referans (groundtruth) haritası Şekil 3.1'de verilmiştir.



Şekil 3.1 KSC verisi (a) RGB görüntüsü (b) kesin referans haritası

3.1.2 Salina Valley Veri Seti

Güney Kaliforniya'daki Salinas Vadisi'nde AVIRIS sensörü tarafından elde edilmiş ve yüksek uzamsal çözünürlüğe (3.7 metrelik piksel) sahip bir veri setidir. Görüntü 0,4 - 2,5 μm aralığında spektral kapsama alanına sahip, 217×512 piksel ve 224 bant içermektedir. Su buharı soğurma bantları ve gürültülü bantları çıkardıktan sonra toplam 204 banttan oluşan veri elde edilmiştir. 16 adet sınıfını olan HS verinin tekli spektral bant görüntüsü ve kesin referans (groundtruth) haritası Şekil 3.2'de verilmiştir.




Şekil 3.2 Salinas valley verisi (a) tekli spektral bant görüntüsü (b) kesin referans haritası

3.1.3 Botswana Veri Seti

31 Mayıs 2001 tarihinde Botswana Okavango Deltası üzerinden alınmış NASA Hyperion veri setidir. 10 nm aralıklarla 400-2500 nm'lik EM spektrumu kapsayan ve 242 bant içeren bir veridir. Uzamsal boyut 1476×256 ve çözünürlüğü 30 metredir. Su buharı soğurma bantları ve gürültülü bantları çıkardıktan sonra toplam 145 banttan oluşan veri seti elde edilmiştir. Veri mevsimsel bataklıklardaki arazi örtü tiplerini, bataklıkları ve delta'nın uzak bölümünde bulunan daha kuru ormanlık alanları temsil


eden 14 tanımlanmış sınıftan oluşmaktadır. RGB görüntüsü ve kesin referans (groundtruth) haritası Şekil 3.3'de verilmiştir.



Şekil 3.3 Botswana verisi (a) RGB görüntüsü (b) kesin referans haritası

3.1.4 Pavia University Veri Seti

8 Temmuz 2002'de kuzey italya pavia üniversitesi mühendislik okulu üzerinden ROSIS sensörü tarafından elde edilmiştir. Veri setinde 115 spektrum bant bulunmaktadır ve 0.43-0.86 μm aralığını kapsamaktadır. Gürültülü bantları çıkardıktan sonra 103 bant elde edilmiştir. Uzamsal boyut 610×340 ve çözünürlüğü 1.3 metredir. 9 adet sınıfını olan HS verinin RGB görüntüsü ve kesin referans (groundtruth) haritası Şekil 3.4'de verilmiştir.




Şekil 3.4 Pavia university verisi (a) RGB görüntüsü (b) kesin referans haritası

3.1.5 Washington, DC Mall Veri Seti

Washington, DC kentsel alan üzerinde hava aracı üzerindeki HYDICE hiperspektral sensörü tarafından elde edilmiştir. 210 bant içerir, görünür ve kızılötesi spektrumun 0,4-2,4 μm 'lik bölümünü kapsar. Su buharı soğurma bantlarını çıkardıktan sonra 191 bant elde edilmiştir. Uzamsal boyutu 1280×307 ve çözünürlüğü 2.8 metredir. 7 adet sınıfı olan HS verinin sahte renk yapay görüntüsü ve kesin referans (groundtruth) haritası Şekil 3.5'de verilmiştir.



(a)



(b)

Şekil 3.5 Washington, DC Mall verisi (a) döndürülmüş üç kanal yapay görüntüsü (kullanılan bantlar R:60, G:27, B:17) (b) kesin referans haritası

Tüm hiperspektral veri kümelerindeki sınıfların orjinal isimleri ve kesin referans piksel sayıları Çizelge 3.1'de verilmiştir.

Çizelge 3.1 Hiperspektral veri kümelerindeki sınıf isimleri ve kesin referans piksel sayıları

Sınıf No.	Salinas Valley		Botswana		KSC		Pavia Uni.		DC Mall	
	İsmi	Boyut	İsmi	Boyut	İsmi	Boyut	İsmi	Boyut	İsmi	Boyut
S1	Brocoli green	2009	Water	270	Scrub	761	Asphalt	6631	Roof	3834
S2	Brocoli gre w2	3726	Hippo grass	101	Willow	243	Meadows	18649	Road	416
S3	Fallow	1976	Floodplain grasses1	251	Cabbage hamm	256	Gravel	2099	Trail	175
S4	Fallow rough plow	1394	Floodplain grasses2	215	Cabbage palm	252	Trees	3064	Grass	1928
S5	Fallow smooth	2678	Reeds1	269	Slash pine	161	Metal sheets	1345	Tree	405
S6	Stubble	3959	Riparian	269	Oak	229	Bare soil	5029	Water	1224
S7	Celery	3579	Firescar2	259	Hardwood swamp	105	Bitumen	1330	Shadow	97
S8	Grapes untrained	11271	Island interior	203	Graminoid marsh	431	Bricks	3682		
S9	Soi vinyard develop	6203	Accacia woodlands	314	Spartina marsh	520	Shadows	947		
S10	Com sen. green w.	3278	Accacia shrublands	248	Cattail marsh	404				
S11	Lettuce4wk	1068	Accacia grasslands	305	Salt marsh	419				
S12	Lettuce5wk	1927	Short mopane	181						
S13	Lettuce6wk	916	Mixed mopane	268						
S14	Lettuce7wk	1070								
S15	Vineyard	7268								
S16	Vineyard ver.	1807								
Toplam Piksel		54129	3153		3781		42766		8079	

3.2 Performans Değerlendirme Ölçütleri

Karışıklık matrisi (confusion matrix) makine öğrenme algoritmasının performansını değerlendirmek için gerçek ve tahmin edilen sınıflandırma sonuçları hakkında bilgi içeren spesifik bir tablodur. Matris, Çizelge 3.2'de verilmiş olup satırlar test kümesindeki örneklere ait gerçek sayıları, sütunlar ise öğrenme algoritması yoluyla öngörülen tahminlemeyi ifade eder.

Çizelge 3.2 Karışıklık matrisi

		Tahmin edilen sınıf		Toplam
		Pozitif	Negatif	
Gerçek sınıf	Pozitif	TP True Pozitif	FN False Negatif	Gerçek Pozitif sayısı
	Negatif	FP False Pozitif	TN True Negatif	Gerçek Negatif
Toplam		Tahmin Pozitif sayısı	Tahmin Negatif sayısı	Toplam Örnek sayısı

Sınıflandırma sonuçlarına göre dört durum gözlemlenir,

- **True Pozitif (TP):** Gerçek değer pozitif olduğu doğru tahmindir, doğru tespit.
- **True Negatif (TN):** Gerçek değer negatif olduğu doğru tahmindir, doğru rededilme.
- **False Pozitif (FP):** Gerçek değer negatif olduğu yanlış tahmindir, yanlış tespit.
- **False Negatif (FN):** Gerçek değer pozitif olduğu yanlış tahmindir, yanlış rededilme.

TSS problemlerinde veri kümeleri genellikle dengesiz bir dağılıma sahiptir. Veri kümesindeki negatif (hedef olmayan, arka plan) sınıf sayısı, pozitif (hedef) sınıf sayısına kıyasla çok çok büyüktür. Bu durum, sınıflandırıcıların performansını değerlendirmek için kullanılan Ortalama Sınıflandırma Oranı (OSO, Average Classification Rate) uygun bir ölçüt olmamasına neden olur. Örneğin, bir sınıflandırıcı tüm verileri negatif sınıf olarak sınıflandırılması durumunda bile (hedef sınıfa ait pozitif sınıfı tespit edememesi durumu) negatif sınıf sayısının çok yüksek olması nedeniyle OSO skoru hala yüksek olarak elde edilir. Bu nedenle, dengesiz dağılıma sahip verilerin sınıflandırma performansını değerlendirmek için literatürde Dengeli Sınıflandırma Oranı (DSO, Balanced Classification Rate) adı verilen ölçüt önerilmiştir [70]. DSO skoru hem düşük false pozitif hem de false negatif oranına bağlıdır. DSO, ancak hem true pozitif hem de true negatif oranları yüksek olduğunda büyük değeri olabilir. En iyi değer 100%, en kötü 0%'a ulaşır. DSO, True pozitif oranı (TPO, Recall, hassasiyet (sensitivity)) ve True negatif oranı (TNO, Özgünlük (Specificity)) ortalaması ile bulunmaktadır,

$$DSO = \frac{TPO(Recall, sensitivity) + TNO(Specificity)}{2} \quad (3.1)$$

Diğer kullandığımız ana performans ölçütü F-metriği (FM) 'dir. FM, literatürde hedef tespiti problemlerinde sonuçları değerlendirmek için kullanılmaktadır. Hatırlama (Recall) ve Kesinlik (Precision) sonuçlarının ağırlıklı harmonik ortalamasıdır ve en iyi 1 en kötü 0 değerini alır. Aşağıdaki şekilde formüle edilmiştir.

$$F\text{-Metriği} = 2 \times \frac{Hatırlama (Recall) \times Kesinlik (Precision)}{Hatırlama (Recall) + Kesinlik (Precision)} \quad (3.2)$$

Her iki performans metriğinde kullanılan;

- **Hatırlama (Recall):** Gerçek değeri pozitif olup pozitif olarak sınıflandırılanların, gerçek değeri pozitif olanların tümüne oranıdır. Hassasiyet veya true pozitif oranı (TPO) olarak adlandırılır. Yüksek hatırlama değeri yüksek tespit oranını gösterir.

$$\text{Hatırlama(Recall)} = \frac{TP}{TP + FN} \quad (3.3)$$

- **Kesinlik (Precision):** Gerçek değeri pozitif olup pozitif olarak sınıflandırılanların, pozitif değere sınıflandırılanların tümüne oranıdır. Pozitif tahmin değeri (PTD, positive predictive value) olarak adlandırılır. Yüksek kesinlik değeri düşük yanlış alarm oranını (False Alarm Rate) gösterir.

$$\text{Kesinlik (Precision)} = \frac{TP}{TP + FP} \quad (3.4)$$

- **Özgünlük (Specificity):** Gerçek değeri negatif olup negatif sınıflandırılanların, gerçek değeri negatif olanların tümüne oranıdır. True negatif oranı (TPO) olarak adlandırılır.

$$\text{Özgünlük (Specificity)} = \frac{TN}{TN + FP} \quad (3.5)$$

TOPLULUK ÖĞRENME YÖNTEMİ İLE DVVT SINIFLANDIRMA PERFORMANSININ GELİŞTİRİLMESİ

4.1 Giriş

Bu bölümde, HSG sınıflandırma problemlerinde TÖ yaklaşımı kullanılarak DVVT performansını arttırmak amaçlanmıştır. TÖ yöntemi olarak torbalama metodu ile veri birleştirmesi için çoğunluk oylaması (ÇO) ve ağırlıklı oylama (AO) teknikleri seçilmiştir. Ağırlıklandırma için yeni bir metod olarak korelasyon katsayıları hesaplamasına dayalı ağırlık kestirimi önerilmiştir. Bu teknikte, her bir taban sınıflandırıcı arasındaki korelasyon ağırlık katsayılarını bulmak için hesaplanmaktadır. Önerilen yöntemin performansını nesnel ve istatistiksel doğrulamak için sınıflandırma amacıyla üç farklı sensörden elde edilmiş üç ayrı hiperspektral görüntü seçilmiştir. ÇO ve AO birleştirme yöntemleri ile ayrı ayrı elde edilen topluluk öğrenmeli DVVT sonuçları, hem kendi aralarında hem de klasik DVVT ile karşılaştırılarak sınıflandırma performansı üzerindeki kazanımlar değerlendirilmiştir.

4.2 Deneysel Model

4.2.1 Önerilen Ağırlıklandırma ve Birleştirme Yöntemi

Teorik altyapı bölümünde açıklandığı gibi torbalama tekniği, her bir taban DVVT sınıflandırıcısını eğitmek için kullanılacak M farklı rastgele çoğaltılmış eğitim veri setleri oluşturur. Taban sınıflandırıcılar bu eğitim veri setleri ile eğitildikten sonra yeni veri kümesi test edilerek her piksel için M adet sınıf etiketi oluşturulmuştur. Her piksel için oluşturulan sınıf etiketleri arasındaki ikili korelasyon katsayıları hesaplanarak ortalaması alınmış ve bu değer veri birleştirme sürecinde her bir taban sınıflandırıcı

ağırlıklarını belirlemek için kullanılmıştır. Korelasyon katsayısına dayanan ağırlıkları hesaplama yöntemi için matematiksel formül şu şekilde tanımlanmıştır,

$$w_i = \frac{1}{M} \sum_{k=1}^M \rho(f_i, f_k) \quad (4.1)$$

Burada $\rho(f_i, f_k)$ bağımsız olarak eğitilmiş her taban DVVT'den elde edilen sınıf etiketleri arasındaki ikili korelasyon katsayısıdır. Korelasyon katsayıları elde ettikten sonra her pikselin nihai sınıf etiketini bulmak için, literatürde konik ve konveks olarak ifade edilen iki farklı ağırlık atama yöntemi kullanılmıştır [86]. Konik kombinasyon, tüm ağırlıkların pozitif değerlere sahip olduğu $w_i \in \mathbb{R}_+$ ağırlıklı kombinasyon yöntemlerinden biridir. Konveks kombinasyon ise konik kombinasyonun özel biçimi olup tüm ağırlıkların pozitif değerlere sahip olduğu ve normalleştirildiği $w_i \in \mathbb{R}_+$, $\sum_i w_i = 1$ yöntemidir. Ağırlıklı kombinasyon eşitlik 4.2'de verilmiştir.

$$f = \sum_{i=1}^M w_i f_i, \quad \{f_i, i=1, \dots, M\} \quad (4.2)$$

Eğer $w_i \geq 0$ ise bu yöntem konik kombinasyon, $\sum_i w_i = 1, w_i \geq 0$ ise Konveks kombinasyon'dur.

Bu çalışmada, veri birleştirmesinde ÇO ve AO (konik ve konveks ağırlıklandırma) ayrı ayrı uygulanmıştır. Önerilen algoritmanın basamakları aşağıdaki gibidir.

1. *Orjinal eğitim veri setini her sınıftan rastgele seç,*
2. *Orjinal eğitim veri seti ile aynı boyutta M adet rastgele alt eğitim setlerini oluştur (torbalama tekniği),*
3. *Her bir alt eğitim setleri ile taban DVVT'leri yeni veri seti için ayrı ayrı eğit,*
4. *Her bir taban DVVT sonuçlarının korelasyon katsayılarını kullanarak ağırlık katsayılarını hesapla,*
5. *Her piksel için nihai sınıf etiketlerini tahmin etmek için ÇO, konik ve konveks AO tekniklerini uygula,*
6. *Klasik ve TÖ DVVT için DSO skorlarını hesapla.*

4.2.2 Parametre Seçimi

Bu algoritmada, torbalama yöntemi için 30 farklı alt eğitim veri seti ($M = 30$) ve her bir taban sınıflandırıcı için sigma parametresi ($\sigma = 0.1$) olan RTF çekirdek fonksiyonu seçilmiştir. Ana (orjinal) eğitim veri setleri, HS veriye ait her sınıftan 10% oranında rastgele seçilmiştir. Daha doğru bir karşılaştırma için, her sınıf için algoritma 20 kez tekrarlanmış ve hesaplanan DSO'ların ortalama ve standart sapmaları hesaplanmıştır. Tüm sınıflar için en iyi DSO kalın yazı tipleri kullanılarak vurgulanmıştır. Ayrıca, uygulanan yöntemlerin genel performansını görmek için ortalama tüm sınıf (overall) performansları da hesaplanmıştır.

4.3 Deneysel Sonuçlar

4.3.1 KSC Hiperspektral Veri Seti için Deneysel Sonuçlar

Klasik DVVT ve farklı kombinasyon yöntemleri ile önerilen TÖ yöntemleri için her sınıfa ait hesaplanan DSO ortalamaları ve standart sapmaları Çizelge 4.1'de verilmiştir.

Çizelge 4.1 KSC veri seti için hesaplanan klasik ve TÖ-DVVT DSO sonuçları

Sınıf No.	Eğitim boyutu	DSO (ortalama± standart sapma, %)			
		Klasik DVVT	Çoğunluk Oylamalı TÖ-DVVT	Ağırlıklı (Konik) TÖ-DVVT	Ağırlıklı (Konveks) TÖ-DVVT
S1	76	67.21±6.09	69.47±3.95	70.28±3.96	70.78±3.90
S2	24	74.13±3.55	73.34±4.47	73.90±4.24	74.21±3.98
S3	26	66.11±9.60	67.58±4.73	69.54±5.74	70.43±5.76
S4	25	67.61±9.12	69.34±6.08	71.12±5.77	71.73±5.75
S5	16	68.43±4.24	68.93±3.83	69.58±3.50	69.75±3.32
S6	23	68.35±8.80	70.27±5.53	71.47±5.03	71.75±4.70
S7	11	67.2±11.21	69.48±8.16	70.36±9.77	70.85±9.74
S8	43	70.38±3.21	70.50±2.93	70.74±2.92	70.77±2.85
S9	52	69.66±5.47	69.58±4.18	70.40±3.88	70.47±3.79
S10	40	71.80±3.76	71.94±3.24	72.31±3.15	72.45±2.96
S11	42	73.32±4.19	73.08±4.18	73.35±4.23	73.36±4.22
S12	50	70.44±5.66	72.00±3.75	72.65±3.36	72.75±3.26
S13	93	67.67±11.66	67.83±3.54	69.42±3.57	69.87±4.13


KSC sınıfları için TÖ yöntemleri ile klasik DVVT arasındaki performans değerlendirmesini Çizelge 4.2'de sunulmuştur. Çizelge 4.2 incelendiğinde, ağırlıksız çoğunluk oylama TÖ yöntemi ile tüm sınıflar için performans artışı sağlanamamıştır. Ancak tüm sınıf ortalamasında az da olsa bir performans artışı (0.85%) sağlanmıştır.

Ağırlıklı konik kombinasyonda sınıf 2 hariç tüm sınıflarda DSO başarımlarının daha iyi olduğu tespit edilmiştir. Konik kombinasyon yönteminde tüm sınıf iyileştirme kazancı 1.75% olup ÇO yönteminden daha iyidir. Ağırlıklı konveks kombinasyon yöntemi tüm sınıflar için en iyi DSO başarımlarına sahiptir. Konveks kombinasyonundaki genel iyileştirme oranı 2.07 % ile ağırlıksız ve konik kombinasyon yöntemlerinden daha iyidir.

Çizelge 4.2 KSC veri seti için TÖ-DVVT yöntemleri ile elde edilen performans artışları (klasik DVVT'ye göre)

Sınıf No.	Performans Artışı (%)		
	Çoğunluk Oylamalı TÖ-DVVT	Ağırlıklı (Konik) TÖ-DVVT	Ağırlıklı (Konveks) TÖ-DVVT
S1	+2.26	+3.07	+3.57
S2	-0.79	-0.23	+0.08
S3	+1.47	+3.43	+4.32
S4	+1.73	+3.51	+4.12
S5	+0.50	+1.15	+1.32
S6	+1.92	+3.12	+3.40
S7	+2.28	+3.16	+3.65
S8	+0.12	+0.36	+0.39
S9	-0.08	+0.74	+0.81
S10	+0.14	+0.51	+0.65
S11	-0.24	+0.03	+0.04
S12	+1.56	+2.21	+2.31
S13	+0.16	+1.75	+2.20
Ortalama	+0.85	+1.75	+2.07

Klasik ve önerilen TÖ- DVVT'leri kullanarak oluşturulan KSC veri setinin nihai sınıflandırma haritaları Şekil 4.1'de verilmiştir.



(a) (b) (c) (d)
Şekil 4.1 KSC verisi için sınıflandırma haritaları (a) klasik DVVT (b) çoğunluk oylamalı TÖ-DVVT (c) ağırlık oylamalı (konik) TÖ-DVVT (d) ağırlık oylamalı (konveks) TÖ-DVVT

4.3.2 Botswana Hiperspektral Veri Seti için Deneysel Sonuçlar

Geleneksel ve farklı kombinasyon yöntemleri önerilen TÖ-DVVT'lerle her sınıf için hesaplanan DSO ortalama ve standart sapma skorları Çizelge 4.3'te verilmiştir.

Çizelge 4.3 Botswana veri seti için hesaplanan klasik ve TÖ-DVVT DSO sonuçları


Sınıf No.	Eğitim boyutu	DSO (ortalama± standart sapma, %)			
		Klasik DVVT	Çoğunluk Oylamalı TÖ-DVVT	Ağırlıklı (Konik) TÖ-DVVT	Ağırlıklı (Konveks) TÖ-DVVT
S1	27	70.82±16.30	72.07±6.35	76.01±5.98	77.40±6.39
S2	10	68.17±10.26	69.97±7.42	72.38±9.90	73.17±10.30
S3	25	72.71±13.91	71.12±5.88	74.03±8.34	75.22±8.43
S4	22	71.60±15.00	68.72±7.35	72.75±7.64	74.14±7.76
S5	27	67.46±10.10	69.32±4.10	71.7±3.97	72.59±3.98
S6	27	69.84±8.23	69.10±6.71	71.90±4.00	73.05±3.52
S7	26	69.07±12.39	71.16±3.75	72.82±3.54	73.26±3.79
S8	20	65.58±10.32	70.39±4.55	72.81±6.86	73.90±7.09
S9	32	69.27±11.29	71.01±4.42	73.77±4.28	75.00±4.51
S10	25	69.37±6.56	69.92±3.87	73.51±3.22	74.04±3.12
S11	31	72.08±10.09	70.36±5.25	73.26±5.03	74.19±4.53
S12	18	71.77±14.50	69.77±6.73	71.79±9.77	72.84±9.99
S13	27	63.45±6.70	66.04±3.27	67.34±3.15	68.06±3.16
S14	10	70.02±13.76	70.63±9.83	70.81±11.72	71.47±11.75

Çizelge 4.4 Botswana veri seti için TÖ-DVVT yöntemleri ile elde edilen performans artışları (klasik DVVT'ye göre)

Sınıf No.	Performans Artışı (%)		
	Çoğunluk Oylamalı TÖ-DVVT	Ağırlıklı (Konik) TÖ-DVVT	Ağırlıklı (Konveks) TÖ-DVVT
S1	+1.25	+5.19	+6.58
S2	+1.80	+4.21	+5.00
S3	-1.59	+1.32	+2.51
S4	-2.88	+1.15	+2.54
S5	+1.86	+4.24	+5.13
S6	-0.74	+2.06	+3.21
S7	+2.09	+3.75	+4.19
S8	+4.81	+7.23	+8.32
S9	+1.74	+4.50	+5.73
S10	+0.55	+4.14	+4.67
S11	-1.72	+1.18	+2.11
S12	-2.00	+0.02	+1.07
S13	+2.59	+3.89	+4.61
S14	+0.61	+0.79	+1.45
Ortalama	+0.58	+3.22	+4.20

Botswana sınıfları için DSO başarımları artışları Çizelge 4.4'de gösterilmiştir. Performans artışı KSC sınıflarıyla benzerlik göstermektedir. ÇO yöntemi ile tüm sınıflar için performans artışı sağlanamamıştır, ancak genel sınıf ortalaması başarımları artışı 0.58%'dir. Ağırlıklı konik ve konveks kombinasyon yöntemlerinde tüm sınıfların için daha iyi DSO performansı elde edilmiştir. Tüm sınıf iyileştirme oranları, konik kombinasyonda 3.22%, konveks'te ise diğerlerinden daha iyi oran olan 4.20%'dir.

Geleneksel ve önerilen topluluk öğrenmeli DVVT'leri kullanarak oluşturulan Botswana veri kümesinin nihai sınıflandırma haritaları Şekil 4.2'de verilmiştir.



Şekil 4.2 Botswana verisi için sınıflandırma haritaları (a) klasik DVVT (b) çoğunluk oylamalı TÖ-DVVT (c) ağırlık oylamalı (konik) TÖ-DVVT (d) ağırlık oylamalı (konveks) TÖ-DVVT

4.3.3 Pavia University Hiperspektral Veri Seti için Deneysel Sonuçlar

Geleneksel ve önerilen TÖ-DVVT'lerle her sınıf için hesaplanan DSO ortalama ve standart sapma skorları Çizelge 4.5'te verilmiştir.

Çizelge 4.5 Pavia University veri seti için hesaplanan klasik ve TÖ-DVVT DSO sonuçları


Sınıf No.	Eğitim boyutu	DSO (ortalama± standart sapma, %)			
		Klasik DVVT	Çoğunluk Oylamalı TÖ-DVVT	Ağırlıklı (Konik) TÖ-DVVT	Ağırlıklı (Konveks) TÖ-DVVT
S1	663	71.85±0.79	72.68±0.84	72.82±0.87	72.82±0.87
S2	1865	71.60±1.17	71.72±0.60	71.79±0.59	71.79±0.59
S3	210	69.35±2.90	71.44±1.25	71.67±1.26	71.67±1.26
S4	306	71.92±1.36	72.42±1.03	72.60±1.03	72.60±1.03
S5	135	74.86±2.27	75.35±2.29	75.59±2.22	75.59±2.22
S6	503	62.30±5.19	62.35±4.29	62.43±4.31	62.43±4.31
S7	133	64.26±11.42	70.69±2.21	72.21±2.92	72.83±2.87
S8	368	72.65±2.10	73.84±1.72	74.06±1.71	74.06±1.71
S9	95	64.10±11.05	71.71±3.62	72.68±3.69	72.96±3.63

Çizelge 4.6 Pavia University veri seti için TÖ-DVVT yöntemleri ile elde edilen performans artışları (Klasik DVVT'ye göre)

Sınıf No.	Performans Artışı (%)		
	Çoğunluk Oylamalı TÖ-DVVT	Ağırlıklı (Konik) TÖ-DVVT	Ağırlıklı (Konveks) TÖ-DVVT
S1	+0.83	+0.97	+0.97
S2	+0.12	+0.19	+0.19
S3	+2.09	+2.32	+2.32
S4	+0.50	+0.68	+0.68
S5	+0.49	+0.63	+0.63
S6	+0.05	+0.13	+0.13
S7	+6.43	+7.95	+8.57
S8	+1.19	+1.41	+1.41
S9	+7.61	+8.58	+8.86
Ortalama	+2.15	+2.47	+2.64

Pavia sınıfları için DSO performans artışları Çizelge 4.6'de verilmiştir. Bazı sınıf için 1%'in altında artışlar olmasına rağmen tüm önerilen yöntemlerle tüm sınıflar için performans iyileştirmesi elde edilmiştir. ÇO tabanlı topluluk öğrenme yöntemi için genel performans artışı 2.15% olup diğer iki HS veri setlerindeki ÇO yöntemi sonuçları ile karşılaştırıldığında daha iyi değerler verdiği gözlemlenmiştir. Ağırlıklı konik ve konveks kombinasyon yöntem başarımları diğer iki HS veri setlerindeki sonuçlar gibi ağırlıksız yöntemlere göre daha iyi DSO performansı vermiştir. Tüm sınıf iyileştirme oranları, konik kombinasyonda 2.47%, konveks'te ise en iyi oran olan 2.64%'dür.

Klasik ve önerilen topluluk öğrenmeli DVVT'leri kullanarak oluşturulan Pavia university veri setinin nihai sınıflandırma haritaları Şekil 4.3'de verilmiştir.



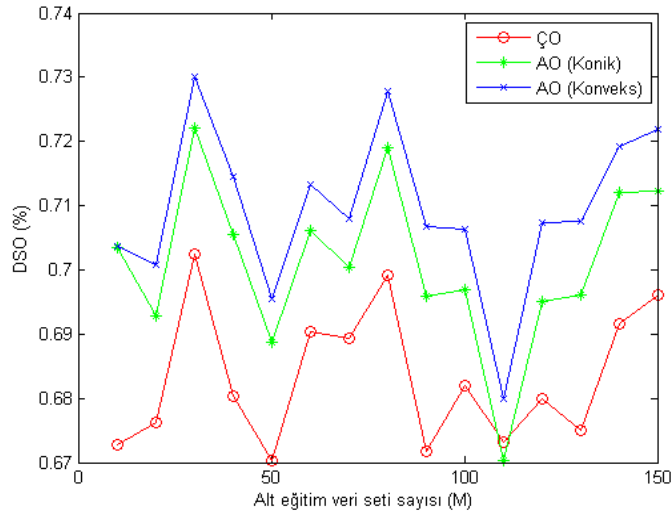
(a) (b) (c) (d)

Şekil 4.3 Pavia university verisi için sınıflandırma haritaları (a) klasik DVVT (b) çoğunluk oylamalı TÖ-DVVT (c) ağırlık oylamalı (konik) TÖ-DVVT (d) ağırlık oylamalı (konveks) TÖ-DVVT


Performans iyileştirmesinin yanı sıra, her üç HS veri seti için klasik ve topluluk öğrenmeli DVVT'lerin DSO standart sapma sonuçları değerlendirildiğinde, torbalama yönteminin tekil DVVT'yi daha kararlı hale getirdiğini söyleyebiliriz.

4.3.4 Alt Eğitim Veri Seti Sayısına Göre Değerlendirme Sonuçları

Bu çalışmada ayrıca, önerilen torbalama yöntemlerinin sınıflandırma skorlarını alt eğitim veri seti sayısına göre değerlendirdik. Bu amaçla, KSC S3 ve Botswana S8 sınıfları seçilmiş ve hesaplanan DSO değerleri alt eğitim veri seti sayısına (M) karşı grafiği çizdirilmiştir. KSC S3 ve Botswana S8 sınıflarına ait grafikler Şekil 4.4 ve 4.5'de sırasıyla verilmiştir.



Şekil 4.4 KSC S3 sınıfı için alt eğitim veri seti sayısına karşı hesaplanan ortalama DSO sonuçları



Şekil 4.5 Botswana S8 sınıfı için alt eğitim veri seti sayısına karşı hesaplanan ortalama DSO sonuçları

Grafiklerde de görüldüğü gibi DSO başarımı ile alt eğitim sayısı arasında mantıksal bir ilişki tespit edilememiştir. Bununla birlikte, farklı alt eğitim sayısı durumunda önerilen üç farklı kombinasyon yönteminin sınıflandırma performans artış oranlarının sırasıyla konveks, konik ve ÇO yöntemleriyle elde edildiği görülmüştür.

4.4 Değerlendirme

HSG üzerinde klasik DVVT'nin sınıflandırma performansını artırmak için ağırlıksız ve ağırlıklandırılmış veri birleştirme yöntemleri kullanarak topluluk öğrenmeli DVVT tasarlanmıştır. Konik ve konveks yöntemlerinde ağırlık katsayılarını tanımlamak için korelasyona dayalı ağırlık atama tekniği önerilmiştir. HS veri setleri üzerinde yapılan uygulamalarda önerilen algoritmaların gürbüzlüğü doğrulanmıştır. Önerilen ağırlık verme yöntemi ile oluşturulan topluluk öğrenmeli DVVT'lerin genel performanslarının sınıflandırma doğruluğu açısından klasik DVVT'ye göre iyi olduğu gözlemlenmiş olup TÖ yönteminin sınıflandırıcı performansını artırmada ve daha kararlı hale getirmede alternatif bir yöntem olduğu değerlendirilmiştir.

HİPERSPEKTRAL HEDEF TESPİTİ İÇİN KÜÇÜK EĞİTİM SETİ İLE ÇEKİRDEK PARAMETRESİ DEĞİŞİMLİ TOPLULUK ÖĞRENME YÖNTEMİ ÖNERİMİ

5.1 Giriş

Sınır betimlemeli sınıflandırıcılar doğrusal olmayan dağılım gösteren verileri tanımlayabilmek için çekirdek fonksiyonları kullanabilme esnekliğine sahiptirler. Çekirdek fonksiyonları orijinal veriyi daha yüksek boyutlu öznitelik uzayına taşıyarak verinin doğrusal ayrılabilmesine ve sınıflandırıcıların daha iyi sonuç vermesini sağlarlar [87]. Bununla birlikte, uygun çekirdek ve hassas parametrelerini belirlemek çözülmesi gereken kritik ve zaman alıcı bir konudur. Sınır betimlemeli yöntemler için bir başka problemde, küçük örnek eğitim sayısı olan yüksek boyutlu veri kümelerinde veri dağılımını modellemede kararsız olabilmeleri ve bu durumda düşük performansa neden olmasıdır [28]. Bu bölümde, eğitim örneği sayısı çok küçük olsa bile taban sınıflandırıcısında kullanılan çekirdek fonksiyonu parametrelerinin optimizasyonu yapılmadan, HSG üzerinde hedef tespiti performansını artırmak için topluluk yöntemlerinden esinlenen yeni bir algoritma sunulmuştur. Önerilen bu yöntemde birden fazla DVVT çekirdek fonksiyonu parametre değeri değiştirilerek eğitilmiş ve her DVVT'nin sonuçları belirli füzyon kurallarına dayalı olarak birleştirilmiştir. Buna ek olarak, DSO skorlarına dayalı seçmeli TÖ yöntemi önerilmiştir. Önerilen teknikler iki farklı HSG verisine uygulanmış ve elde edilen sonuçlar farklı eğitim örneği sayısına göre klasik DVVT ile kıyaslanmıştır.

5.2 Deneysel Model

5.2.1 Önerilen Algoritma

Birden fazla DVVT sınıflandırıcısının her biri için parametre (sigma σ) değeri değiştirilen RTF çekirdek fonksiyonu kullanarak eğitilmiş ve elde edilen sınıflandırıcı sonuçları ÇO ve AO kombinasyon kuralları kullanılarak birleştirilmiştir. Her bir DVVT'nin eğitimi sırasında doğrulama kümeleri (validation set) kullanılarak DSO skorları hesaplanmış ve ağırlıklı oylamada her sınıflandırıcıya ağırlık atamak için kullanılmıştır. Ayrıca, birleştirme işleminde tüm sınıflandırıcıları kullanmak yerine sınıflandırıcıların uygun olanlarını seçerek daha fazla performans artımı hedeflenmiştir. Bu amaçla, doğrulama sürecinde tüm taban sınıflandırıcılar arasından en iyi DSO skorlarına sahip yalnızca üç temel sınıflandırıcı seçilmiştir. Önerilen algoritmanın işlem basamakları aşağıda verilmiştir.

1. *Hedef sınıftan eğitim ve doğrulama veri setini rastgele seç,*
2. *Her bir DVVT'yi farklı sigma değerleriyle ayrı ayrı eğit,*
3. *Sınıflandırıcıların ağırlık katsayılarını elde etmek için doğrulama veri setlerini kullanarak DSO skorlarını hesapla,*
4. *Seçmeli TÖ için DSO skorlarına göre en iyi üç sınıflandırıcıyı seç,*
5. *Her piksel için nihai etiketleri elde etmek için ÇO ve AO birleştirme tekniklerini uygula,*
6. *Yeni veri seti için klasik ve önerilen algoritmaların DSO skorlarını hesapla.*

5.2.2 Parametre Seçimi

Her bir DVVT sınıflandırıcısı için 5×10^{-6} - 10^1 arasında 5'er kat artırımlarla değişen 10 farklı çekirdek parametresi (σ) değeri belirlenmiştir. Sınıflandırıcıların eğitim sürecinde her bir sınıf için kullanılacak örnek veri setleri iki eşit parçaya bölmüştür. İlk kısım DVVT'yi eğitmek için eğitim veri seti olarak, ikinci kısım ise AO'da her bir sınıflandırıcıya ağırlık atamaya yönelik DSO değerlerini hesaplamak için doğrulama veri seti olarak kullanılmıştır. Önerilen algoritma sonuçlarının klasik DVVT'den daha iyi performansla sahip olup olmadığını değerlendirmek için her bir DVVT'yi kullanılan 10 farklı σ değeriyle ayrı ayrı RTF kullanarak sonuçlarda elde edilmiştir. Ayrıca, eğitim seti boyutlarına karşı önerilen algoritmaların performansları görmek için farklı

büyükliklerdeki eğitim örnekleri için değerlendirme yapılmıştır. Eğitim veri seti boyutları 3-100 ($L=3, 5, 10, 15, 20, 30, 40, 50, 100$) arasında seçilmiştir.

5.3 Deneysel Sonuçlar

5.3.1 DC Mall Hiperspektral Veri Seti için Deneysel Sonuçlar

Klasik DVVT ve önerilen algoritmalara ait hesaplanan DSO skorları Çizelge 5.1'de verilmiştir.

Çizelge 5.1 DC Mall veri seti için hesaplanan klasik, ağırlıklı ve seçmeli sigma TÖ-DVVT DSO sonuçları

Sınıf No.	Eğitim boyutu	Doğr. boyutu	Klasik DVVT	DSO (ortalama± standart sapma, %)		
				Ağırlıksız Sigma TÖ-DVVT	Ağırlıklı Sigma TÖ-DVVT	Seçmeli Sigma TÖ-DVVT
S1	191	191	73.11±1.07	70.00±8.95	77.28±7.63	78.97±6.23
S2	21	20	74.78±4.39	77.38±11.5	79.76±9.09	80.90±8.48
S3	9	8	68.39±2.28	66.85±14.21	73.97±13.44	74.99±13.26
S4	96	96	74.18±2.70	75.15±15.51	79.89±11.27	81.79±9.32
S5	20	20	73.02±2.86	73.02±13.34	78.77±11.66	80.20±10.14
S6	61	61	74.83±1.84	74.98±14.72	79.53±11.07	82.24±8.70
S7	5	4	70.74±2.46	69.89±12.01	73.18±12.29	73.24±12.33

Önerilen yöntemlerin klasik DVVT'ye karşı performans değerlendirmeleri Çizelge 5.2'de gösterilmektedir. Çizelge 5.2'de görüldüğü gibi ağırlıksız topluluk öğrenmeli sigma yöntemi bazı sınıflar için performans artışı sağlarken bazıları için sağlamamıştır. Ağırlıksız yöntem tüm sınıflar için iyi performans göstermezse de (tüm sınıf ortalaması -0.25%), DSO tabanlı ağırlıklı sigma TÖ tüm sınıflar için daha iyi sonuçlar vermiş olup tüm sınıf ortalaması 4.76%'dır. Ağırlıklı seçmeli sigma TÖ yöntemi ile en yüksek DSO performansı elde edilmiştir. Tüm sınıf iyileştirme ortalaması 6.18% olup bu artış oldukça önemli bir iyileştirme değildir.

Çizelge 5.2 DC Mall veri seti için sigma TÖ-DVVT yöntemleri ile elde edilen performans artışları (klasik DVVT'ye göre)

Sınıf No.	Performans Artışı (%)		
	Ağırlıksız Sigma TÖ-DVVT	Ağırlıklı Sigma TÖ-DVVT	Seçmeli Sigma TÖ-DVVT
S1	-3.11	+4.17	+5.86
S2	+2.6	+4.98	+6.12
S3	-1.54	+5.58	+6.61
S4	+0.97	+5.71	+7.62
S5	+0	+5.75	+7.18
S6	+0.15	+4.70	+7.41
S7	-0.85	+2.44	+2.51
Ortalama	-0.25	+4.76	+6.18

Bu çalışmada kullanılan 10 farklı sigma ile ayrı ayrı eğitilen tekil DVVT'ler ile önerilen ağırlıklı ve seçilmiş ağırlıklı yöntemlerin karşılaştırılması Çizelge 5.3'te sunulmuştur. Çizelge 5.3 incelendiğinde, önerilen yöntemlerin 10 farklı sigma değerine sahip her bir tekil DVVT'ye kıyasla da daha iyi performans verdikleri görülmüştür.

Çizelge 5.3 DC Mall veri seti için ağırlıklı sigma TÖ (ATÖ) ve seçmeli sigma TÖ (STÖ) DVVT yöntemleri ile elde edilen performans artışları (klasik DVVT'ye göre)

Sigma	Sımf1		Sımf2		Sımf3		Sımf4		Sımf5		Sımf6		Sımf7	
	ATÖ	STÖ	ATÖ	STÖ	ATÖ	STÖ	ATÖ	STÖ	ATÖ	STÖ	ATÖ	STÖ	ATÖ	STÖ
5×10^{-6}	+5.01	+6.70	+14.77	+15.92	+9.30	+10.33	+5.26	+7.17	+4.94	+6.37	+9.50	+12.21	+8.61	+8.68
2.5×10^{-5}	+4.99	+6.69	+3.16	+4.30	+6.43	+7.46	+4.67	+6.58	+4.17	+5.60	+5.02	+7.74	+3.43	+3.50
1.25×10^{-4}	+4.99	+6.68	+2.20	+3.35	+6.24	+7.27	+4.67	+6.58	+3.85	+5.28	+4.36	+7.08	+2.66	+2.73
6.25×10^{-4}	+4.99	+6.68	+2.09	+3.24	+6.10	+7.13	+4.67	+6.57	+3.81	+5.25	+3.77	+6.48	+2.91	+2.98
0.003125	+5.64	+7.33	+2.14	+3.29	+6.17	+7.20	+4.66	+6.56	+3.83	+5.26	+3.68	+6.40	+2.91	+2.98
0.015625	+3.80	+5.50	+2.13	+3.27	+8.13	+9.16	+4.63	+6.54	+5.78	+7.22	+3.69	+6.41	+0.29	+0.36
0.078125	+2.85	+4.55	+0.60	+1.75	+4.07	+5.10	+13.35	+15.25	+13.44	+14.88	+4.05	+6.77	+1.09	+1.16
0.390625	+2.83	+4.53	+6.66	+7.81	+4.74	+5.77	+5.56	+7.47	+6.27	+7.70	+4.78	+7.49	+0.77	+0.83
1.953125	+2.95	+4.64	+8.84	+9.99	+2.15	+3.18	+4.82	+6.72	+5.87	+7.30	+2.83	+5.54	+0.22	+0.29
9.765625	+3.62	+5.32	+7.16	+8.31	+2.44	+3.47	+4.81	+6.72	+5.49	+6.93	+5.31	+8.02	+1.51	+1.58
Ortalama	+4.17	+5.86	+4.98	+6.12	+5.58	+6.61	+5.71	+7.62	+5.75	+7.18	+4.70	+7.41	+2.44	+2.51

5.3.2 Salinas Valley Hiperspektral Veri Seti için Deneysel Sonuçlar

Salinas valley veri seti sınıfları için benzer sonuçlar elde edilmiş olup DSO skorları Çizelge 5.4'de verilmiştir.

Çizelge 5.4 Salinas valley veri seti için hesaplanan klasik, ağırlıklı ve seçmeli sigma TÖ-DVVT DSO sonuçları

DSO (ortalama± standart sapma, %)						
Sınıf No.	Eğitim boyutu	Doğr. boyutu	Klasik DVVT	Ağırlıksız Sigma TÖ-DVVT	Ağırlıklı Sigma TÖ-DVVT	Seçmeli Sigma TÖ-DVVT
S1	101	100	70.91±2.07	70.36±16.87	79.14±9.75	80.01±8.91
S2	186	186	72.96±1.16	71.74±11.71	77.19±7.97	78.80±6.93
S3	99	98	74.75±2.73	76.12±10.90	78.77±8.57	80.34±7.04
S4	69	69	71.99±1.80	71.84±12.45	75.05±9.44	78.63±7.05
S5	134	133	73.20±4.29	75.14±11.86	76.94±10.08	79.40±8.78
S6	198	197	73.66±4.67	72.81±9.85	79.32±9.55	80.83±8.44
S7	179	178	73.61±1.44	72.03±12.23	79.23±7.79	80.30±7.22
S8	563	563	69.98±0.61	68.65±10.10	74.15±8.21	75.74±7.03
S9	310	309	74.28±3.29	76.02±15.34	79.42±12.34	82.25±9.26
S10	164	163	72.84±1.09	72.21±8.93	75.56±5.20	77.29±3.50
S11	53	53	74.90±2.62	76.18±11.10	79.82±7.60	81.30±5.65
S12	96	96	74.70±0.83	75.03±12.17	78.38±9.41	80.54±7.20
S13	46	46	77.26±3.02	79.28±15.60	82.52±12.01	84.62±9.85
S14	53	53	75.17±3.00	73.26±11.22	81.30±9.83	83.27±8.81
S15	363	363	73.69±4.46	76.34±10.31	78.52±6.89	79.11±6.04
S16	90	90	71.17±2.19	71.34±7.83	74.43±2.85	73.83±2.56

Çizelge 5.5 Salinas valley veri seti için sigma TÖ-DVVT yöntemleri ile elde edilen performans artışları (klasik DVVT'ye göre)

Performans Artışı (%)			
Sınıf No.	Ağırlıksız Sigma TÖ-DVVT	Ağırlıklı Sigma TÖ-DVVT	Seçmeli Sigma TÖ-DVVT
S1	-0.55	+8.23	+9.09
S2	-1.22	+4.23	+5.82
S3	+1.37	+4.02	+5.59
S4	-0.15	+3.06	+6.64
S5	+1.94	+3.74	+6.20
S6	-0.85	+5.66	+7.17
S7	-1.58	+5.62	+6.69
S8	-1.33	+4.17	+5.76
S9	+1.74	+5.14	+7.97
S10	-0.63	+2.72	+4.45
S11	+1.28	+4.92	+6.40
S12	+0.33	+3.68	+5.84
S13	+2.02	+5.26	+7.36
S14	-1.91	+6.13	+8.10
S15	+2.65	+4.83	+5.42
S16	+0.17	+3.25	+2.65
Ortalama	+0.21	+4.67	+6.32

Çizelge 5.5'de görüldüğü gibi, ağırlıksız TÖ sigma yöntemi bazı sınıflar için performans artışı sağlarken bazıları için sağlamamıştır. Tüm sınıf ortalama performans artışı 0.21% olup azda olsa bir kazanç elde edilmiştir. Ağırlıklı sigma yöntemi için, tüm sınıflarda daha iyi DSO performansı görülmüştür. Genel iyileştirme ortalaması 4.67% olup bu sonuç anlamlı bir artıştır. Ağırlıklı seçmeli yöntemde ise sınıf 16 hariç diğer yöntemlerden daha iyi sonuç alınmıştır. Bu yöntem için genel iyileştirme ortalaması 6.32% olup oldukça değerli bir artıştır.

Önerilen yöntemlerin, kullanılan 10 farklı sigma değerleri ile eğitilen tekil DVVT'lere göre DSO skorları bazında performans karşılaştırılması Çizelge 5.6'da gösterilmiştir. Görüldüğü gibi sınıf 16 haricinde önerilen yöntemlerin klasik DVVT'lere göre daha iyi performans sağladıkları gözlemlenmiştir. Sadece sınıf 16 için sigma değeri ($\sigma = 1.95$) olduğu durumda klasik DVVT'nin daha iyi sonuç verdiği tespit edilmiştir.

Çizelge 5.6 Salinas valley veri seti için ağırlıklı sigma TÖ (ATÖ) ve seçmeli sigma TÖ (STÖ) DVVT yöntemleri ile elde edilen performans artışları (klasik DVVT'ye göre)

Sigma	Sınıf1		Sınıf2		Sınıf3		Sınıf4		Sınıf5		Sınıf6		Sınıf7		Sınıf8	
	ATÖ	STÖ	ATÖ	STÖ	ATÖ	STÖ	ATÖ	STÖ	ATÖ	STÖ	ATÖ	STÖ	ATÖ	STÖ	ATÖ	STÖ
5×10^{-6}	+11.8	+12.6	+4.83	+6.41	+3.42	+5.00	+5.17	+8.75	+9.57	+12.0	+3.61	+5.11	+6.82	+7.90	+4.21	+5.80
2.5×10^{-5}	+8.63	+9.50	+4.50	+6.09	+2.52	+4.09	+3.23	+6.81	+1.49	+3.95	+3.47	+4.98	+6.26	+7.33	+3.93	+5.53
1.25×10^{-4}	+8.62	+9.48	+4.53	+6.12	+2.44	+4.01	+3.07	+6.65	+0.99	+3.45	+3.50	+5.01	+6.23	+7.30	+3.94	+5.53
6.25×10^{-4}	+8.61	+9.47	+4.49	+6.07	+2.42	+4.00	+3.12	+6.70	+1.50	+3.95	+3.47	+4.98	+6.11	+7.19	+3.92	+5.51
0.003125	+8.69	+9.55	+4.51	+6.09	+2.43	+4.00	+3.13	+6.71	+1.78	+4.24	+3.54	+5.05	+6.24	+7.32	+3.61	+5.21
0.015625	+8.69	+9.55	+6.08	+7.66	+2.26	+3.83	+3.22	+6.81	+1.81	+4.26	+6.60	+8.11	+6.62	+7.69	+5.03	+6.62
0.078125	+9.77	+10.6	+5.24	+6.83	+11.2	+12.8	+6.40	+9.99	+1.19	+3.65	+18.6	+20.1	+7.15	+8.23	+5.47	+7.07
0.390625	+7.71	+8.58	+2.77	+4.36	+4.97	+6.55	+2.18	+5.76	+13.6	+16.0	+4.30	+5.80	+3.24	+4.32	+4.19	+5.79
1.953125	+4.87	+5.73	+2.70	+4.29	+4.25	+5.82	+0.52	+4.10	+3.12	+5.58	+4.49	+5.99	+3.74	+4.82	+3.68	+5.28
9.765625	+4.90	+5.76	+2.66	+4.24	+4.21	+5.79	+0.54	+4.13	+2.37	+4.83	+5.00	+6.50	+3.81	+4.89	+3.69	+5.29
Ortalama	+8.23	+9.09	+4.23	+5.82	+4.02	+5.59	+3.06	+6.64	+3.74	+6.20	+5.66	+7.17	+5.62	+6.69	+4.17	+5.76

Çizelge 5.6 Salinas valley veri seti için ağırlıklı sigma TÖ (ATÖ) ve seçmeli sigma TÖ (STÖ) DVVT yöntemleri ile elde edilen performans artışları (klasik DVVT'ye göre) (devamı)

Sigma	Sımf9		Sımf10		Sımf11		Sımf12		Sımf13		Sımf14		Sımf15		Sımf16	
	ATÖ	STÖ	ATÖ	STÖ	ATÖ	STÖ	ATÖ	STÖ	ATÖ	STÖ	ATÖ	STÖ	ATÖ	STÖ	ATÖ	STÖ
5x10 ⁻⁶	+9.24	+12.0	+3.21	+4.94	+5.32	+6.80	+5.50	+7.66	+6.13	+8.23	+4.09	+6.06	+2.21	+2.81	+4.11	+3.51
2.5x10 ⁻⁵	+3.49	+6.31	+3.02	+4.75	+2.90	+4.38	+3.06	+5.22	+3.40	+5.50	+3.77	+5.75	+2.02	+2.62	+4.11	+3.51
1.25x10 ⁻⁴	+3.15	+5.98	+3.03	+4.76	+2.83	+4.31	+3.22	+5.38	+3.22	+5.33	+3.78	+5.75	+2.01	+2.61	+4.10	+3.50
6.25x10 ⁻⁴	+3.12	+5.95	+3.03	+4.76	+2.83	+4.31	+3.20	+5.36	+3.13	+5.23	+3.77	+5.74	+2.01	+2.61	+4.10	+3.50
0.003125	+3.13	+5.95	+2.47	+4.20	+2.81	+4.29	+3.20	+5.36	+3.02	+5.13	+5.33	+7.30	+1.97	+2.57	+6.07	+5.47
0.015625	+3.13	+5.96	+4.82	+6.56	+3.07	+4.55	+3.20	+5.36	+2.39	+4.49	+13.6	+15.6	+2.04	+2.63	+6.15	+5.55
0.078125	+4.37	+7.19	+3.22	+4.95	+10.7	+12.2	+4.78	+6.94	+5.57	+7.68	+7.44	+9.42	+15.8	+16.4	+2.12	+1.52
0.390625	+12.9	+15.7	+1.97	+3.71	+7.37	+8.85	+4.01	+6.17	+12.4	+14.5	+6.16	+8.14	+6.93	+7.52	+1.13	+0.53
1.953125	+4.39	+7.22	+1.48	+3.21	+6.03	+7.51	+3.22	+5.38	+6.09	+8.20	+6.42	+8.40	+6.63	+7.23	-0.31	-0.91
9.765625	+4.46	+7.28	+0.91	+2.65	+5.30	+6.77	+3.34	+5.50	+7.21	+9.32	+6.83	+8.80	+6.66	+7.26	+0.93	+0.33
Ortalama	+5.14	+7.97	+2.72	+4.45	+4.92	+6.40	+3.68	+5.84	+5.26	+7.36	+6.13	+8.10	+4.83	+5.42	+3.25	+2.65

5.3.3 Farklı Büyüklükteki Eğitim Setleri için Deneysel Sonuçlar

Bu çalışmada, önerilen algoritmalar her bir sınıf için küçük ve orta ölçekli eğitim setleri ile de değerlendirilmiştir. Örnek eğitim seti boyutları 3-100 (L = 3, 5, 10, 15, 20, 30, 40, 50, 100) arasında seçilmiştir. İki HS veri kümesinin her sınıf için ayrı ayrı ve tüm sınıf ortalaması başarımları sonuçları sırasıyla Çizelge 5.7 ve 5.8'de verilmiştir.

Çizelge 5.7 DC Mall veri seti için farklı eğitim seti büyüklüklerine göre ağırlıklı sigma TÖ-DVVT yöntemi ile elde edilen performans artışları (klasik DVVT'ye göre)

Sınıf No.	Eğitim seti büyüklüğü									
	3	5	10	15	20	30	40	50	100	
S1	+1,35	+4.11	+4.56	+4.69	+5.42	+5.58	+5.98	+4.91	+5.31	
S2	+0,39	+4.57	+5.57	+4.69	+5.42	+5.58	+5.98	+4.91	+5.31	
S3	+0,92	+3.68	+4.66	+5.30	+5.97	+5.38	+5.89	+5.84	+5.70	
S4	-0,69	+3.80	+5.50	+5.62	+5.96	+5.63	+6.44	+6.33	+5.45	
S5	-0,22	+4.29	+5.53	+5.72	+5.67	+4.96	+5.62	+6.26	+6.12	
S6	+1,97	+5.15	+4.92	+5.87	+5.03	+5.38	+3.88	+4.06	+4.21	
S7	-0,64	+3.02	+3.84	+3.90	+3.43	+4.81	+4.36	+4.35	+4.70	
Ortalama	+0.44	+4.09	+4.94	+5.11	+5.27	+5.33	+5.45	+5.24	+5.26	

Çizelge 5.8 Salinas valley veri seti için farklı eğitim seti büyüklüklerine göre ağırlıklı sigma TÖ-DVVT yöntemi ile elde edilen performans artışları (klasik DVVT'ye göre)

Sınıf No.	Eğitim seti büyüklüğü								
	3	5	10	15	20	30	40	50	100
S1	+0,28	+5.28	+3.28	+4.11	+5.03	+4.21	+3.82	+3.82	+4.66
S2	+0,12	+4.99	+5.04	+5.53	+5.45	+4.40	+6.00	+5.05	+5.41
S3	+0,55	+3.68	+5.66	+3.83	+5.14	+4.16	+4.02	+5.42	+5.84
S4	-0,69	+4.63	+3.60	+5.62	+5.61	+5.87	+3.91	+5.78	+5.60
S5	+1,03	+4.35	+5.17	+5.59	+5.29	+5.35	+5.92	+5.98	+6.24
S6	-0,90	+3.67	+5.19	+5.92	+5.43	+5.60	+4.97	+5.82	+5.15
S7	-0,65	+3.26	+5.18	+6.72	+5.70	+5.80	+6.80	+5.23	+5.31
S8	-0,01	+2.12	+5.22	+3.45	+4.67	+4.07	+3.58	+4.57	+4.78
S9	+1,21	+3.93	+5.75	+5.69	+5.33	+4.69	+6.24	+6.01	+4.52
S10	-0,07	+3.17	+3.41	+3.74	+3.88	+4.06	+4.36	+4.37	+3.61
S11	+0,44	+4.69	+3.62	+7.07	+5.30	+5.31	+5.78	+4.86	+5.71
S12	-0,46	+2.17	+4.97	+3.61	+5.00	+5.05	+4.03	+5.56	+3.92
S13	-0,41	+2.65	+5.04	+3.42	+4.95	+6.36	+4.97	+5.02	+5.27
S14	0,23	+3.63	+5.55	+6.22	+4.69	+4.91	+6.24	+6.03	+5.61
S15	-0,17	+2.79	+3.07	+4.76	+4.62	+4.04	+4.39	+4.23	+4.05
S16	-0,10	+2.26	+4.44	+3.91	+4.17	+2.80	+4.25	+3.15	+2.88
Ortalama	+0.03	+3.58	+4.64	+4.95	+5.02	+4.79	+4.96	+5.06	+4.91

Her iki çizelge de görüldüğü gibi, $L = 3$ 'te (oldukça küçük eğitim seti) azda olsa artışlar sağlanmasına rağmen, $L = 5$ 'den itibaren oldukça değerli performans kazanımları elde edildiği tespit edilmiştir. Her iki HS verisi için, 10 -100 eğitim seti büyüklüğü aralığında genel ortalamaları karşılaştırdığında, elde edilen artışın neredeyse istikrarlı ($\sim\% 5$) olduğu ve düşük eğitim seti boyutlarında da aynı performans kazançlarının elde edildiği görülmüştür. Sonuçlar değerlendirildiğinde, önerilen yöntemler ile HSG'de KÖS probleminin (Hughes olayı) çözüldüğü ve bu yöntemlerle çok küçük örnek eğitim seti büyüklüğünde bile performans artışı elde edildiği kanıtlanmıştır.

5.4 Değerlendirme

TÖ yönteminden ilham alınarak HSG ile hedef tespit probleminde performans üzerinde kazanç elde etmek için yeni bir yaklaşım önerilmiştir. Bu teknikte sınıflandırıcıların çekirdek fonksiyonu parametresini optimize etmemize gerek kalmamıştır. Her bir DVVT farklı parametre değerine sahip RTF çekirdek fonksiyonu ile eğitilmiş, daha sonra ağırlıksız ve ağırlıklı oylamaya dayalı kombinasyon işlemleri uygulanmıştır. Önerilen bu yöntem, tek bir sınıflandırıcıya optimum çekirdek fonksiyonu elde etmek için çekirdek fonksiyonlarını birleştirmeyi öneren çoklu çekirdek algoritmasından

(Multiple Kernel Algorithm) farklılık göstermektedir. Ayrıca, birleştirme işleminde tüm sınıflandırıcıları seçmek yerine en iyi sınıflandırıcıları seçmek için DSO skoru tabanlı sınıflandırıcı seçme yaklaşımı önerilmiştir. Bu çalışmalara ek olarak, yüksek boyutlu verilerin işlenmesinde çok önemli olan KÖS probleminin bu yöntemlerle çözülebildiği gözlemlenmiştir. Önerilen algoritmaların performansı iki farklı HS görüntüsü üzerinde değerlendirilmiştir. Yapılan deneysel çalışmalar sonucunda sunulan yöntemlerin, hiperspektral hedef tespiti probleminde az sayıda eğitim örneği kullanılması durumunda bile fizibilitesini ve etkinliğini göstermiştir.



HİPERSPEKTRAL SINIFLANDIRMA/HEDEF TESPİTİ PROBLEMİNDE TOPLULUK ÖĞRENME YÖNTEMİNDE ÇEŞİTLİLİK İÇİN YENİ BENZERLİK METRİĞİ ÖNERİMİ

6.1 Giriş

Bölüm 2'de açıklandığı gibi daha performanslı bir TÖ yöntemi için ana faktörün sınıflandırıcılar arasında çeşitliliği artırmak olduğu teorik olarak belirtilmiştir. Bununla birlikte yapılan çalışmalarda çeşitliliğin TÖ için faydalı ya da zararlı olabileceği hala net değildir. Üstelik yalnızca hedef sınıfa ait sınırlı eğitim örnekleri olması nedeniyle HSG'de TSS ile etkin bir TÖ yöntemi uygulaması sınırlı ve zor bir çalışmadır.

Çeşitliliği ölçmek ve oluşturmak amacıyla, istatistikte genel amaçlı tanımlanmış ve birçok alanda kullanılan veya belirli alanlar/amaçlar için özel olarak oluşturulmuş benzerlik (similarity) ve farklılık (dissimilarity) metrikleri geliştirilmiştir. Bu bölümde HS hedef tespit problemi için TÖ yönteminde kullanmak amacıyla yeni bir benzerlik metriği önerilmiştir. Önerilen metrik, arka plan (hedef olmayan) sınıf piksel sayısının (oldukça çok) hedef sınıf piksel sayısı (oldukça az) üzerinde hakim olduğu HS hedef tespit problemini veri yapısı dikkate alınarak formüle edilmiştir. Bu metrik TÖ'deki her bir taban sınıflandırıcı arasındaki çeşitliliği ölçmek ve veri birleştirme sırasında sınıflandırıcılara ağırlık atamak için kullanılmıştır. Çeşitliliği yüksek olan sınıflandırıcılara daha fazla ağırlık atanmıştır.

Yeni metrik ile önerilen TÖ yöntemi, klasik sınıflandırıcılar ve literatürde yaygın olarak kullanılan dört adet kıyaslama (benchmarking) metrikleri ile oluşturulan TÖ yöntemleri arasında karşılaştırmalı çalışma ve analiz gerçekleştirilmiştir. Bu amaçla, farklı sensörlerde elde edilmiş üç adet hiperspektral veri kümesi kullanılmıştır. Aynı zamanda,

HSG uygulamalarındaki KÖS sorunu için de çözüm olabileceğini araştırmak için önerilen metrikle uygulanan TÖ yöntemi farklı eğitim boyutları ile denenmiştir.

6.2 Önerilen Benzerlik Metriği

Önerilen benzerlik metriği ikili (pairwise) tipi ölçüttür. İkili olumsuzluk tablosu Çizelge 6.1'de verilmiştir. Olumsuzluk çizelgesi iki girişin aynı anda gösterildiği özel bir frekans dağıtım tablosudur. Çizelgedeki değişkenler (a, b, c, d) hedef tespit probleminde taban sınıflandırıcı çiftleri arasındaki her bir piksel için hedef/hedef olmayan (arka plan) etiketlendirmesinin isabet sayıları olarak yazılmaktadır.

Çizelge 6.1 İkili olumsuzluk tablosu

		C_j	
		Hedef(1)	Arka plan (-1)
C_i	Hedef(1)	a	b
	Arka plan (-1)	c	d

Burada aynı piksel için;

- **a**, her iki sınıflandırıcı'nın (C_i , C_j) hedef sınıf olarak tespit ettiği eşleşme sayısını,
- **b**, C_i sınıflandırıcısının hedef olarak tespit ettiği ancak C_j sınıflandırıcısının hedef olmayan sınıf olarak tespit ettiği eşleşme sayısını,
- **c**, C_i sınıflandırıcısının hedef olmayan sınıf olarak tespit ettiği ancak C_j sınıflandırıcısının hedef sınıf olarak tespit ettiği eşleşme sayısını,
- **d**, her iki sınıflandırıcı'nın (C_i , C_j) hedef olmayan sınıf olarak tespit ettiği eşleşme sayısını göstermektedir.

Hedef tespit probleminde, hedef olmayan arka plan'a ait piksel sayısı hedef sınıf sayısı üzerinde baskındır. Bu husus göz önüne alınarak TÖ yöntemindeki her bir sınıflayıcı sonucunda hedef olmayan sınıf etiketlerinin (-1) çoğunlukla olacağı, bunda sınıflandırıcı arasındaki benzerliği belirleyebileceği kanısına varılmıştır. Bu nedenle olumsuzluk tablosunda hedef olmayan durumlara dayalı yeni bir ikili benzerlik metriği tasarlanmıştır. Yeni benzerlik metriği $S_{i,j}$ aşağıdaki eşitlikte verilmiştir.

$$S_{i,j} = \left| \frac{d}{b+d} - \frac{b}{b+d} \right| \quad (6.1)$$

Bu metrik iki sınıflandırıcı arasındaki doğru şekilde tanımlanan hedef olmayan sınıf etiketlendirme oranı ile hatalı reddedilen hedef olmayan sınıf etiketlendirme oranı arasındaki göreceli farkını bulur. Bu metriğin farklılık formu (dissimilarity) ise aşağıdaki şekilde bulunur,

$$D_{i,j} = 1 - S_{i,j} \quad (6.2)$$

Farklılık metrikleri en azından aşağıdaki üç önermeyi (axiom) sağlamalıdır [88].

Simetri (symmetry): C_i ve C_j arasındaki farklılık değeri C_j ve C_i arasındaki farklılık değeri ile aynı olmalı,

$$D(C_i, C_j) = D(C_j, C_i) \quad (6.3)$$

Minimalite (Minimality): C_i ve C_j birbirleri ile eşlenirse C_i ve C_j arasındaki farklılık değeri sıfır olmalı,

$$D(C_i, C_j) = 0, \text{ if } C_i = C_j \quad (6.4)$$

Negatif olmama (Nonnegativity): C_i ve C_j arasındaki farklılık değeri her zaman sıfıra eşit veya büyük olmalıdır.

$$D(C_i, C_j) \geq 0 \quad (6.5)$$

Yeni sunulan metrik yukarıda belirtilen üç önermeyi de sağlamaktadır. Bu metrikte farklılık değerleri $[0, 1]$ arasındadır. Eğer değer 1 ise sınıflandırıcılar istatistiksel olarak bağımsız 0 ise benzeştirler (identical).

6.3 Deneysel Model

6.3.1 Yeni Benzerlik Metriği ile Önerilen Algoritma

TÖ yönteminde çeşitliliği artırmak için önerilen yeni benzerlik (farklılık) metriği kullanılarak diğerlerinden farklı olan sınıflandırıcılara daha fazla ağırlık verecek ağırlık atama yöntemi tasarlanmıştır. Uygulanan TÖ'de M adet taban sınıflandırıcı olduğu kabul edelim. Önerilen farklılık (benzerlik) metriğini kullanarak her bir taban sınıflandırıcının diğer taban sınıflandırıcılarla ikili (pairwise) çeşitlilik (farklılık) ölçümleri hesapladığında Eşitlik 6.6'da verilen köşegeni sıfır olan MXM farklılık matrisi elde edilir.

$$\mathbf{D} = \begin{pmatrix} 0 & \cdots & D_{1,M} \\ \vdots & \ddots & \vdots \\ D_{M,1} & \cdots & 0 \end{pmatrix} \quad (6.6)$$

Her bir taban sınıflandırıcı için çeşitlilik katsayısı ($D_i, i = 1 \dots M$) matrisdeki her satırın (taban sınıflandırıcının diğer taban sınıflandırıcılarla ikili çeşitlilik ölçümleri) ortalamasını alınarak hesaplanır. Matematiksel ifadesi aşağıda verilmiştir.

$$D_i = \frac{1}{M} \sum_{j=1}^M D(f_i, f_j), \quad i = 1, \dots, M \quad (6.7)$$

Topluluktaki tüm sınıflandırıcılar için çeşitlilik katsayılarının hesaplanmasından sonra M adet çeşitlilik katsayıları ($D_i, i = 1 \dots M$) elde edilmiştir. Bu katsayılar ağırlıklandırılmış oylamada her bir taban sınıflandırıcıya ağırlık atmak için kullanılmıştır. Atanacak ağırlıklar toplam ağırlık içerisindeki yüzdelere göre elde edilmiştir. Ağırlıkların hesaplanması için matematiksel eşitlik aşağıda verilmiştir.

$$w_i = 100 \times \frac{D_i}{\sum_{j=1}^M D_j}, \quad i = 1, \dots, M \quad (6.8)$$

Önerilen yöntemin algoritması Çizelge 6.2’de verilmiştir.

Çizelge 6.2 Yeni farklılık metriği ile önerilen TÖ algoritması

Giriş:

Tek sınıf sınıflandırıcı, *TSS*.

TÖ’deki taban sınıflandırıcısı sayısı, *M*.

Eğitim veri seti büyüklüğü, *L*.

Eğitim veri seti, $X_i, i = 1, \dots, L$

İşlem:

for $j = 1, \dots, M$;

$X_j = \text{Bootstrap}(X)$; % Orjinal veri setinden rastgele alt örnek veri setleri oluştur

$f_j = \text{TSS}(X_j)$; % Alt örnek veri setleri ile eğitilen taban sınıflandırıcı sonuçlarını

(sınıf etiketleri) elde et

end.

$D_{i,j} = 1 - S_{i,j}$; % Her bir çift taban sınıflandırıcı arasındaki farklılık değerleri ile çeşitlilik matrisini oluştur

$D_i = \text{mean}(D_{i,j})$; % $D_{i,j}$ matrisinin satır ortalamalarını al

$w_i = p(D_i)$; % Ağırlıkları belirlemek için oranları hesapla

Çıktı:

ÇÖ

$f_{\text{ço}} = \text{argmax}_i (f_i)$; % çoğunluk oylaması ile nihai etiketleri bul

AO

$f_{\text{ao}} = \text{argmax}_i (w_i f_i)$; % Ağırlıklı oylama ile nihai etiketleri bul

6.3.2 Parametre Seçimi

Bu çalışmada TSDVM ve DVVT taban sınıflandırıcılar olarak seçilmiş olup uygulama sonuçları her iki sınıflandırıcı için elde edilmiştir. TÖ'deki taban sınıflandırıcı sayısı $M = 30$ olarak seçilmiştir. Her iki TSS için RTF çekirdek fonksiyonu seçilmiş ve RTF parametresi sigma (σ) aşağıdaki hesaplama ile belirlenmiştir.

$$\sigma = \sqrt{\frac{\sum_d \|x^k - \bar{x}\|^2}{L}} \quad (6.9)$$

Burada \bar{x} HS veri setindeki L adet verinin merkez noktasıdır. Önerilen yöntemin performansını farklı eğitim seti boyutlarında incelemek için çok küçük boyuttan orta büyüklüğe kadar eğitim örneği sayısı ($L = 3, 6, 10, 20, 50$) seçilmiştir. Çarpık (skewed) sonuçlardan kurtulmak için her bir veri setinde uygulamalar 30 kez tekrarlanmış ve hesaplanan performans metriklerinin ortalaması alınmıştır. Jaccard, Q istatistiği, ÇA ve BE, önerilen metriğimize karşı kıyaslama (benchmarking) metrikleri olarak kullanılmıştır. Her bir HS veri seti için deneysel uygulamalar aşağıdaki sıraya göre gerçekleştirilmiştir.

1. Yeni metrik ile önerilen yöntemin performansı sabit eğitim örneği boyutu $L = 10$ kullanılarak, klasik, ağırlıksız ÇO ve AO'lu (kıyaslama metrikleri kullanılarak elde edilen ağırlıklarla) TSS'ler ile karşılaştırılmıştır. Karşılaştırma için her sınıf için hesaplan F-metrik (FM) skorları ve tüm sınıf (overall) FM ortalaması verilmiştir. Sonuçların istatistiksel olarak değerliğini ölçmek için ortalama sıra skorları da (OSS, Average rank scores) hesaplanmıştır. En düşük ortalama sıra skoruna sahip yöntem istatistiksel olarak en iyi performansa sahip olduğu anlamına gelmektedir.
2. Önerilen yöntemin farklı eğitim boyutlarındaki ($L = 3, 6, 10, 20, 50$) performansları ve KÖS probleminin çözülmesinde etkili olup olmadığı test edilmiştir. Her bir örnek eğitim seti sayıları için her sınıfa ait FM skorları elde edilmiş ve tüm sınıf FM değerleri hesaplanmıştır. İstatistiksel değerlendirme için OSS sonuçları da verilmiştir.
3. Ayrıca, her veri seti için sınıflandırma performanslarını değerlendirmek için ortalama DSO sonuçları ile OSS'da sunulmuştur.

6.4 Deneysel sonuçlar

6.4.1 Salinas Valley Hiperspektral Veri Seti için Deneysel Sonuçlar

Her bir sınıfa ait FM skorları, tüm sınıf ortalama FM ve ortalama sıralama testi sonuçları Çizelge 6.3'te gösterilmiştir. En iyi sonuçlar kalın yazı tipiyle işaretlenmiştir. Çizelge 6.3 incelendiğinde aşağıdaki değerlendirmeler yapılabilir.


DVVT Sınıflandırıcısı: Jaccard ve Q istatistiği tabanlı AO yöntemleri tüm sınıflar için performansı düşürürken, ÇO ile ÇA ve BE tabanlı ağırlık yöntemler genel olarak performansı artırmıştır. Yeni metric ile önerilen yöntem ise sınıf 11 ve sınıf 16 hariç diğer tüm 14 tane sınıf için en iyi artış değerlerine sahip olduğu tespit edilmiştir. Önerilen yöntem için tüm sınıf ortalama FM skoru 0.596'dır. Bu yöntemde standart DVVT ve ikinci en iyi yöntem (ÇA tabanlı AO)'e göre elde edilen ortalama kazanç sırasıyla 0.066, 0.044 olup oldukça iyi bir artıştır. Çizelgede verilen OSS'da bakıldığında önerilen yöntemin diğerlerine göre açık ara önde olduğu görülmüştür.

TSDVM Sınıflandırıcısı: ÇA tabanlı AO ve önerilen yöntem dışındaki tüm yöntemler çok az sınıf hariç kötü performans göstermiştir. ÇA ise düşük bir artış sağlamıştır. Öte yandan önerilen yöntem sınıf 11, 14 ve 16 dışındaki 13 sınıf için iyi bir performans kazancı sağlamıştır. Tüm sınıf ortalama FM skoru 0,601'dir. Bu yöntemde klasik DVVT ve en iyi ikinci yönteme (ÇA tabanlı AO) göre elde edilen ortalama kazanç sırasıyla 0.032, 0.031'dir. OSS'da bakıldığında önerilen yöntemin diğerlerine göre istatistiksel olarak değerli olduğu gösterilmiştir.

Şekil 6.1'de farklı büyüklükteki eğitim seti boyutlarında önerilen yöntemin diğer yöntemlere göre performans kıyaslaması (FM ortalamaları) grafiksel olarak verilmiştir. Jaccard ve Q tabanlı yöntem performansları diğerlerine kıyasla oldukça kötü olması nedeniyle grafiklerde çizdirilmemiştir. Şekil 6.1'de görüldüğü gibi önerilen yöntem her iki TSS'da $L = 6$ 'dan itibaren daha iyi başarımler sergilemektedir. Ayrıca, bazı sınıflar (sınıf 5, 7, 9, 13) için $L = 3$ durumunda bile klasik TSS'lara göre daha iyi sonuçlar elde edilmiştir.

Çizelge 6.3 Salinas valley veri seti için her bir sınıf FM, tüm sınıf ortalama FM ve OSS sonuçları ($L = 10$)

SınıfNo.	DVVT							TSDVM						
	Klasik	ÇO	Jacc	Q	ÇA	BE	Öne.	Klasik	ÇO	Jacc	Q	ÇA	BE	Öne.
S1	0,593	0,541	0,512	0,372	0,588	0,555	0,659	0,570	0,521	0,503	0,433	0,567	0,539	0,629
S2	0,575	0,553	0,526	0,385	0,588	0,557	0,681	0,608	0,592	0,572	0,434	0,627	0,595	0,708
S3	0,560	0,538	0,534	0,422	0,579	0,571	0,639	0,539	0,523	0,525	0,428	0,558	0,551	0,579
S4	0,581	0,604	0,565	0,285	0,653	0,607	0,722	0,619	0,623	0,605	0,473	0,652	0,632	0,734
S5	0,542	0,582	0,500	0,201	0,627	0,593	0,709	0,585	0,571	0,551	0,370	0,612	0,586	0,662
S6	0,635	0,636	0,613	0,370	0,659	0,641	0,716	0,649	0,638	0,620	0,446	0,659	0,646	0,735
S7	0,595	0,572	0,554	0,430	0,600	0,584	0,687	0,607	0,588	0,576	0,438	0,618	0,598	0,683
S8	0,488	0,468	0,450	0,381	0,496	0,473	0,544	0,504	0,478	0,471	0,428	0,500	0,488	0,551
S9	0,530	0,541	0,486	0,266	0,588	0,551	0,677	0,613	0,576	0,553	0,439	0,608	0,584	0,682
S10	0,488	0,472	0,470	0,436	0,496	0,494	0,507	0,507	0,497	0,493	0,452	0,514	0,506	0,519
S11	0,396	0,422	0,410	0,358	0,370	0,397	0,276	0,467	0,507	0,521	0,422	0,438	0,454	0,376
S12	0,566	0,544	0,517	0,401	0,583	0,555	0,665	0,603	0,558	0,549	0,451	0,601	0,576	0,695
S13	0,542	0,574	0,503	0,238	0,622	0,577	0,708	0,626	0,596	0,569	0,409	0,636	0,600	0,700
S14	0,580	0,591	0,575	0,411	0,611	0,601	0,628	0,639	0,614	0,604	0,473	0,631	0,615	0,622
S15	0,440	0,441	0,429	0,392	0,464	0,450	0,496	0,492	0,476	0,473	0,442	0,492	0,483	0,523
S16	0,376	0,429	0,463	0,437	0,322	0,377	0,225	0,474	0,501	0,514	0,478	0,412	0,434	0,214
Ortalama	0,531	0,532	0,507	0,362	0,553	0,536	0,596	0,569	0,554	0,544	0,439	0,570	0,555	0,601
OSS	4,125	4,188	5,438	6,625	2,500	3,375	1,750	2,938	4,625	5,313	6,688	2,688	3,875	1,875




Şekil 6.1 Salinas valley verisi için eğitim seti büyüklüklerine göre ortalama FM sonuçları (a) DVVT (b) TSDVM

Farklı eğitim seti boyutlarına göre OSS sonuçları Çizelge 6.4'te verilmiş olup yeni metrik ile önerilen metodun $L = 3$ hariç diğer tüm örnek boyutları için tüm yöntemlerden istatistiksel olarak daha iyi olduğunu göstermektedir.

Çizelge 6.4 Salinas valley verisi için farklı eğitim seti büyüklüklerinde hesaplanan FM değerlerinin OSS sonuçları

Eğitim boyutu	DVVT							TSDVM						
	Klasik	ÇO	Jacc	Q	ÇA	BE	Öne.	Klasik	ÇO	Jacc	Q	ÇA	BE	Öne.
3	1,56	3,94	6,00	7,00	3,19	4,31	2,00	1,56	4,31	6,06	6,38	2,88	4,31	1,88
6	2,88	4,50	5,56	7,00	2,69	3,69	1,69	2,75	4,63	5,38	6,94	2,75	3,81	1,75
10	4,13	4,19	5,44	6,63	2,50	3,38	1,75	2,94	4,63	5,31	6,69	2,69	3,88	1,88
20	3,38	4,63	5,19	6,50	2,63	3,88	1,81	3,25	4,75	5,25	6,44	2,69	3,88	1,75
50	4,06	4,25	5,00	6,38	2,75	3,75	1,81	3,44	5,06	4,88	6,19	2,81	3,88	1,75

Tüm sınıf ortalama DSO ve OSS değerleri sırasıyla Şekil 6.2 ve Çizelge 6.5'te verilmiştir. Yeni metrik ile önerilen yönteme ait DSO skorlarının da oldukça iyi olduğu ve $L = 3$ hariç tüm örnek boyutları için istatistiksel olarak iyi sonuçlar verdiği gözlemlenmiştir.



(a)

(b)

Şekil 6.2 Salinas valley verisi için eğitim seti büyüklüklerine göre ortalama DSO sonuçları (%) (a) DVVT (b) TSDVM

Çizelge 6.5 Salinas valley verisi için farklı eğitim seti büyüklüklerinde hesaplanan DSO değerlerinin OSS sonuçları

Eğitim boyutu	DVVT							TSDVM						
	Klasik	ÇO	Jacc	Q	ÇA	BE	Öne.	Klasik	ÇO	Jacc	Q	ÇA	BE	Öne.
3	1,31	4,13	6,00	7,00	3,13	4,56	1,88	1,38	4,31	6,06	6,38	3,06	4,50	1,69
6	3,00	4,88	5,88	7,00	2,31	3,81	1,13	2,94	4,88	5,94	7,00	2,50	3,75	1,00
10	3,81	4,63	5,75	7,00	2,13	3,38	1,31	3,19	4,88	5,63	7,00	2,38	3,63	1,31
20	3,44	4,94	5,50	7,00	2,25	3,63	1,25	3,19	5,06	5,75	6,69	2,38	3,56	1,38
50	4,00	4,69	5,50	6,25	2,44	3,75	1,38	3,50	5,56	5,50	6,44	2,25	3,50	1,25

Yeni metrik ile uygulanan yöntemin geleneksel TSS'lara karşı performansındaki iyileşmeler farklı örnek eğitim verisi büyüklükleri için Çizelge 6.6'da özetlenmiştir. Çizelge incelendiğinde önerilen yöntemle, $L = 3$ dışında her büyüklükteki örnek için

standart sınıflandırıcılara göre performans artışı sağlamaktadır. Ayrıca, yöntemin özellikle küçük örnek boyutlarında ($L = 6, 10$) daha etkili olduğu, boyut arttıkça performans artışında azalma yaşandığı tespi edilmiştir. FM skoruna göre DVVT ve TSDVM için maksimum artışlar sırasıyla 0.066 ($L = 10$) ve 0.050'dır ($L = 6$). DSO için, 5.06% ($L = 10$) ve 4.76%'dır ($L = 6$).

Çizelge 6.6 Salinas valley veri seti için önerilen yöntemle FM ve DSO (%) skorlarında elde edilen performans artışları (klasik DVVT ve TSDVM'e göre)

Performans metriği	DVVT					TSDVM				
	Eğitim seti boyutu					Eğitim seti boyutu				
	3	6	10	20	50	3	6	10	20	50
FM	-0,001	+0,060	+0,066	+0,032	+0,019	-0,003	+0,050	+0,032	+0,014	+0,007
DSO	-0,11	+4,98	+5,06	+3,69	+2,48	-0,14	+4,76	+4,08	+2,98	+1,89

Salinas Valley veri kümesi için genel bir değerlendirme yapılırsa, yeni metrik ile önerilen yöntem farklı eğitim boyutlarında (özellikle küçük boyutlarda) diğer yöntemlere göre FM ve DSO skorları bazında üstün performans göstermektedir. ÇA tabanlı yöntem ise en iyi ikinci sonuçları vermektedir.

6.4.2 Pavia University Hiperspektral Veri Seti için Deneysel Sonuçlar

Her bir sınıfa ait FM ve tüm sınıf ortalama FM skorları ile OSS testi sonuçları Çizelge 6.7'de verilmiştir. En iyi sonuçlar kalın yazı tipi ile işaretlenmiştir. Çizelge 6.7'e göre değerlendirme yapıldığında;


DVVT Sınıflandırıcısı: Yeni metrik ile önerilen TÖ yöntemi sınıf 5 dışındaki tüm sınıflar için performans artışı sağlarken, diğer yöntemler hemen hemen tüm sınıflar için düşüş göstermiştir. Önerilen yöntem için tüm sınıf ortalama FM 0.5'dir ve standart DVVT'ye göre artış 0.026 olarak elde edilmiştir.

TSDVM Sınıflandırıcısı: DVVT sınıflandırıcısındaki benzer sonuçlar bu sınıflandırıcı içinde elde edilmiştir. Önerilen yöntem için tüm sınıf ortalama FM 0.503'dir ve standart DVVT'ye göre artış 0.018'dir.

Çizelge 6.7 Pavia university veri seti için her bir sınıf FM, tüm sınıf ortalama FM ve OSS sonuçları ($L = 10$)

SınıfNo.	DVVT							TSDVM						
	Klasik	ÇO	Jacc	Q	ÇA	BE	Öne.	Klasik	ÇO	Jacc	Q	ÇA	BE	Öne.
S1	0,519	0,489	0,477	0,408	0,518	0,500	0,564	0,566	0,516	0,502	0,429	0,551	0,525	0,604
S2	0,546	0,492	0,476	0,429	0,525	0,502	0,598	0,517	0,465	0,451	0,402	0,490	0,471	0,554
S3	0,379	0,370	0,368	0,324	0,383	0,378	0,397	0,391	0,383	0,379	0,332	0,395	0,389	0,407
S4	0,412	0,404	0,401	0,353	0,421	0,412	0,449	0,439	0,418	0,410	0,340	0,434	0,420	0,452
S5	0,506	0,356	0,337	0,130	0,401	0,365	0,474	0,488	0,340	0,315	0,137	0,389	0,353	0,444
S6	0,310	0,296	0,292	0,278	0,305	0,297	0,313	0,302	0,288	0,286	0,267	0,295	0,291	0,310
S7	0,496	0,462	0,442	0,385	0,498	0,480	0,537	0,533	0,501	0,492	0,426	0,526	0,516	0,537
S8	0,529	0,496	0,485	0,426	0,519	0,500	0,560	0,513	0,488	0,478	0,423	0,512	0,499	0,560
S9	0,569	0,469	0,445	0,370	0,517	0,487	0,604	0,620	0,562	0,537	0,445	0,601	0,563	0,664
Ortalama	0,474	0,426	0,414	0,345	0,454	0,436	0,500	0,485	0,440	0,428	0,356	0,466	0,447	0,503
OSS	2,333	5,000	6,000	7,000	2,667	3,889	1,111	2,000	5,000	6,000	7,000	2,889	4,000	1,111

DVVT ve TSDVM için, eğitim örneği büyüklüğüne karşı elde edilen tüm sınıf ortalama FM skorları Şekil 6,3'de çizdirilmiştir. Grafikler incelendiğinde her iki TSS için, örnek sayısı ($L = 6$) ve üzerindeki değerlerde önerilen yöntemin daha iyi başarımlar skorları verdiği görülmektedir. Diğer tüm yöntemler her koşulda klasik yöntemlere göre daha kötü sonuçlar vermektedir. OSS'da Çizelge 6.8'de verilmiş olup, yeni metrik ile önerilen yöntemin en iyi sonuçlar verdiği istatistiksel olarak tespit edilmiştir.




Şekil 6.3 Pavia university verisi için eğitim seti büyüklüklerine göre ortalama FM sonuçları (a) DVVT (b) TSDVM

Çizelge 6.8 Pavia university verisi için farklı eğitim seti büyüklüklerinde hesaplanan FM değerlerinin OSS sonuçları

Eğitim boyutu	DVVT							TSDVM						
	Klasik	ÇO	Jacc	Q	ÇA	BE	Öne.	Klasik	ÇO	Jacc	Q	ÇA	BE	Öne.
3	1,00	4,22	6,11	6,11	3,00	4,78	2,00	1,22	4,44	6,11	6,00	3,00	4,56	1,78
6	2,11	5,00	6,00	7,00	2,78	4,00	1,11	1,89	4,89	6,00	7,00	3,00	4,11	1,11
10	2,33	5,00	6,00	7,00	2,67	3,89	1,11	2,00	5,00	6,00	7,00	2,89	4,00	1,11
20	2,89	5,00	5,78	7,00	2,44	3,56	1,33	2,22	5,00	6,00	7,00	2,67	4,00	1,11
50	2,78	5,67	5,78	6,44	2,67	3,67	1,00	2,78	5,56	5,44	6,67	2,78	3,78	1,00

Ortalama DSO ve OSS sonuçları sırasıyla Şekil 6.4 ve Çizelge 6.9'da verilmiştir. Önerilen yöntem sınıflandırma skoruna (DSO) göre de en iyi yöntem olduğu gözlemlenmiştir.



Şekil 6.4 Pavia university verisi için eğitim seti büyüklüklerine göre ortalama DSO sonuçları (%) (a) DVVT (b) TSDVM

Çizelge 6.9 Pavia university verisi için farklı eğitim seti büyüklüklerinde hesaplanan DSO değerlerinin OSS sonuçları

Eğitim boyutu	DVVT							TSDVM						
	Klasik	ÇO	Jacc	Q	ÇA	BE	Öne.	Klasik	ÇO	Jacc	Q	ÇA	BE	Öne.
3	1,11	4,22	6,11	6,11	3,00	4,78	1,89	1,33	4,33	6,11	6,00	3,00	4,67	1,67
6	2,00	4,89	6,00	7,00	2,89	4,11	1,11	1,89	4,89	6,00	7,00	3,00	4,11	1,11
10	2,11	4,89	6,00	7,00	2,78	4,11	1,11	2,00	4,89	6,00	7,00	2,89	4,11	1,11
20	2,56	4,78	6,00	7,00	2,56	4,00	1,11	2,11	5,00	6,00	7,00	2,78	4,00	1,11
50	2,78	5,56	5,67	6,67	2,56	3,78	1,00	2,22	5,56	5,44	7,00	2,78	4,00	1,00

Önerilen TÖ yöntemin ortalama FM ve DSO skorları bazında standart sınıflandırıcılara göre performans artımları (farklı büyüklükteki eğitim sayısına göre) Çizelge 6.10'da verilmiştir. Yöntemin $L = 3$ dışında her eğitim seti büyüklüğünde kazanç sağladığı görülmektedir. Elde edilen maksimum FM artışları DVVT için 0.028 ($L = 6$), TSDVM

için 0.23 ($L = 6$), DSO artışları ise 2.23% ($L = 6$) ve 2.39% ($L = 6$) olarak elde edilmiştir. Ayrıca bu HS verisi için de, yöntemimizin özellikle küçük örnek boyutlarında ($L = 6, 10$) daha etkili olduğunu söylenebilir. Eğitim boyutu arttıkça performans artışı azalmaktadır.

Çizelge 6.10 Pavia university veri seti için önerilen yöntemle FM ve DSO (%) skorlarında elde edilen performans artışları (klasik DVVT ve TSDVM'e göre)

Performans metriği	DVVT					TSDVM				
	Eğitim seti boyutu					Eğitim seti boyutu				
	3	6	10	20	50	3	6	10	20	50
FM	-0,007	+0,028	+0,026	+0,024	+0,018	-0,002	+0,023	+0,018	+0,023	+0,017
DSO	-0,29	+2,23	+2,05	+2,18	+1,59	-0,13	+2,39	+1,87	+2,01	+1,45

Pavia University veri seti için genel bir değerlendirme yapacak olursak, yalnızca önerilen metrik ile uygulanan algoritmanın klasik sınıflandırıcılara göre performans iyileştirmesi elde edildiği diğer tüm yöntemlerde düşüşler yaşandı gözlemlenmiştir. Ayrıca, özellikle küçük örnek eğitim boyutlarında daha iyi iyileştirme sonuçları alınmıştır.

6.4.3 Botswana Hiperpektral Veri Seti için Deneysel Sonuçlar

Çizelge 6.11'de, her bir sınıfa ait FM skorları, tüm sınıf ortalama FM ve OSS testi değerleri verilmiştir. En iyi sonuçlar kalın yazı tipiyle işaretlenmiştir. Her bir sınıflandırıcı için elde edilen sonuçları aşağıda gibi değerlendirebiliriz.

DVVT sınıflandırıcısı: Jaccard ve Q metrikleri ile ağırlıklandırılmış yöntemler tüm sınıflar için performansı düşürürken, diğerleri artış sağlamıştır. Performans artışına göre, ÇA, BE tabanlı yöntemlerle ve önerilen yöntem arasında oldukça yakın sonuçlar elde edilmiştir. Bununla birlikte, ÇA ortalama FM ve sıralama testine göre diğer iki yönteme göre biraz daha iyi bir performans göstermiştir. ÇA, BE ve yeni metrik algoritmaları için ortalama FM skorları sırasıyla 0.599, 0.581 ve 0.594 olup birbirlerine çok yakın değerlerdir. Klasik sınıflandırıcıya göre iyileştirme her üç yöntem içinde yaklaşık 0.13'tür, bu da oldukça önemli bir artıştır.

TSDVM sınıflandırıcısı: Bu sınıflandırıcı ile alınan sonuçlar DVVT'de elde edilenlerle benzerlik göstermektedir. ÇA, BE ve önerilen yöntem arasında oldukça yakın sonuçlar


elde edilmiştir. Ortalama FM değerlerine metodumuz en iyi skorları üretmiştir. Önerilen yöntem için ortalama FM değeri 0.58 ve performans artışı 0.031'dir.

Çizelge 6.11 Botswana veri seti için her bir sınıf FM, tüm sınıf ortalama FM ve OSS sonuçları ($L = 10$)

SınıfNo.	DVVT							TSDVM						
	Klasik	ÇO	Jacc	Q	ÇA	BE	Öne.	Klasik	ÇO	Jacc	Q	ÇA	BE	Öne.
S1	0,596	0,605	0,336	0,028	0,696	0,627	0,827	0,610	0,611	0,602	0,477	0,630	0,617	0,692
S2	0,339	0,460	0,224	0,073	0,446	0,479	0,330	0,434	0,486	0,508	0,483	0,443	0,470	0,373
S3	0,559	0,576	0,236	0,065	0,709	0,688	0,689	0,660	0,620	0,612	0,514	0,649	0,639	0,707
S4	0,471	0,522	0,185	0,043	0,684	0,666	0,619	0,643	0,624	0,614	0,527	0,659	0,642	0,701
S5	0,428	0,488	0,321	0,091	0,575	0,564	0,525	0,500	0,489	0,492	0,450	0,503	0,506	0,469
S6	0,337	0,372	0,274	0,129	0,403	0,403	0,400	0,387	0,390	0,379	0,341	0,401	0,402	0,384
S7	0,489	0,534	0,455	0,159	0,628	0,585	0,741	0,587	0,559	0,541	0,470	0,598	0,578	0,665
S8	0,427	0,578	0,306	0,071	0,627	0,629	0,566	0,542	0,516	0,512	0,454	0,543	0,534	0,564
S9	0,427	0,491	0,271	0,081	0,571	0,566	0,529	0,513	0,526	0,528	0,497	0,538	0,539	0,535
S10	0,515	0,504	0,258	0,088	0,595	0,576	0,590	0,547	0,553	0,549	0,471	0,567	0,564	0,577
S11	0,502	0,567	0,320	0,087	0,647	0,639	0,618	0,547	0,566	0,567	0,500	0,586	0,588	0,616
S12	0,521	0,577	0,217	0,057	0,725	0,679	0,768	0,601	0,592	0,574	0,464	0,627	0,602	0,689
S13	0,383	0,474	0,331	0,135	0,517	0,527	0,450	0,500	0,513	0,523	0,479	0,502	0,512	0,453
S14	0,460	0,483	0,337	0,129	0,557	0,505	0,662	0,623	0,591	0,567	0,417	0,633	0,600	0,700
Ortalama	0,461	0,517	0,291	0,088	0,599	0,581	0,594	0,550	0,545	0,541	0,467	0,563	0,557	0,580
OSS	4,857	3,786	6,000	7,000	1,643	2,143	2,571	4,214	4,286	4,786	6,643	2,500	2,929	2,643

Eğitim seti büyüklüklerine göre ortalama FM'ler Şekil 6.5'te çizdirilmiştir. Grafiklerde görüldüğü gibi, yöntemimiz TSDVM'de $L = 3$ 'de bile en iyi artışa sahip olup tüm eğitim seti büyüklüklerinde iyi değerler üretmiştir. DVVT için, $L = 3,6$ (düşük eğitim veri seti boyutu)'da en iyi performans gösterirken, daha büyük örnek boyutlarında ÇA tabanlı yöntem en iyi sonuçları verdiği görülmüştür. Ancak, önerilen yöntem tüm eğitim seti boyutlarında klasik sınıflandırıcıya göre performans artışı sağlamıştır.

Elde edilen FM değerleri için OSS sonuçları Çizelge 6.12'de gösterilmiştir. Metrik değerimizin çok küçük örnek büyüklüklerinde ($L = 3,6$) istatistiksel olarak daha iyi olduğu, ÇA'nın ise daha büyük boyutlarda iyi sonuçlar verdiği tespit edilmiştir.



(a)

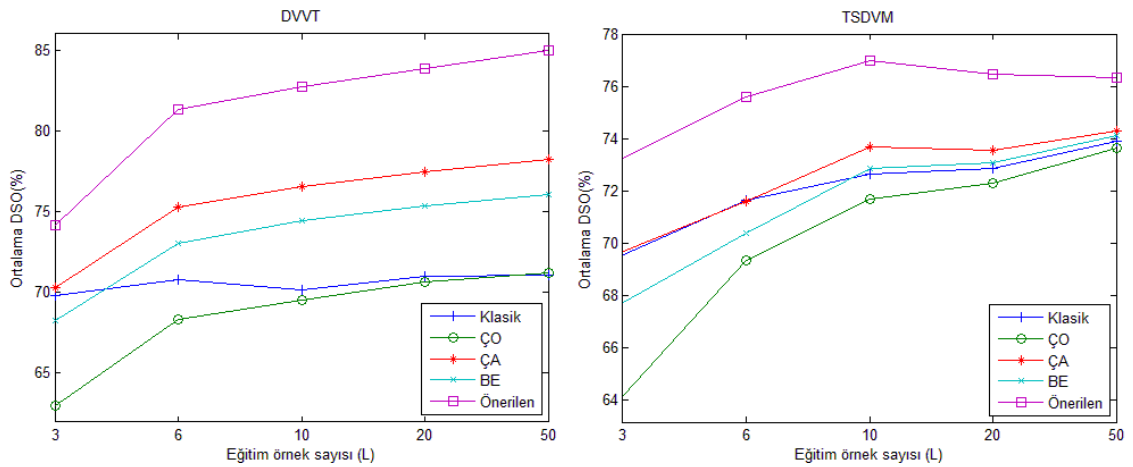
(b)

Şekil 6.5 Botswana verisi için eğitim seti büyüklüklerine göre ortalama FM sonuçları
(a) DVVT (b) TSDVM

Çizelge 6.12 Botswana verisi için farklı eğitim seti büyüklüklerinde hesaplanan DSO değerlerinin OSS sonuçları

Eğitim boyutu	DVVT							TSDVM						
	Klasik	ÇO	Jacc	Q	ÇA	BE	Önc.	Klasik	ÇO	Jacc	Q	ÇA	BE	Önc.
3	3,36	5,00	6,00	6,00	2,21	3,21	1,21	3,50	4,64	6,07	6,07	2,36	3,29	1,21
6	4,64	4,07	6,00	7,00	1,86	2,36	2,07	2,86	4,79	6,00	7,00	2,50	3,36	1,50
10	4,86	3,79	6,00	7,00	1,64	2,14	2,57	4,21	4,29	4,79	6,64	2,50	2,93	2,64
20	4,86	3,79	5,86	7,00	1,79	2,07	2,64	4,64	4,57	4,71	6,29	2,43	2,86	2,50
50	4,86	3,50	5,64	7,00	1,71	2,29	3,00	4,36	4,71	4,43	5,86	2,71	3,21	2,71

Şekil 6.6 ve Çizelge 6.13'te ortalama DSO ve sıra testleri verilmiştir. DSO skorları değerlendirildiğinde önerilen yöntem diğer yöntemler ile ve klasik TSS sonuçlarından oldukça iyi olduğu görülmüştür.



(a)

(b)

Şekil 6.6 Botswana verisi için eğitim seti büyüklüklerine göre ortalama DSO sonuçları (%) (a) DVVT (b) TSDVM

Çizelge 6.13 Botswana verisi için farklı eğitim seti büyüklüklerinde hesaplanan DSO değerlerinin OSS sonuçları

Eğitim boyutu	DVVT							TSDVM						
	Klasik	ÇO	Jacc	Q	ÇA	BE	Öne.	Klasik	ÇO	Jacc	Q	ÇA	BE	Öne.
3	2,71	5,00	6,00	6,00	2,50	3,79	1,00	2,71	4,86	6,00	6,14	2,50	3,93	1,00
6	4,14	4,71	6,00	7,00	2,00	3,14	1,00	2,57	5,00	6,00	7,00	2,57	3,86	1,00
10	4,36	4,64	6,00	7,00	2,00	3,00	1,00	3,79	5,00	5,71	7,00	2,07	3,43	1,00
20	4,43	4,43	6,00	7,00	2,00	3,14	1,00	4,00	5,07	5,64	7,00	2,14	3,14	1,00
50	4,21	4,50	6,00	7,00	2,00	3,29	1,00	4,29	5,50	5,21	6,64	2,29	3,07	1,00

Çizelge 6.14’de yöntemimizin standart TSS’lara göre performansını FM ve DSO skorları bazında özetlenmiştir. Yeni metrik çok küçük örnek boyutlarında ($L = 3$) bile performansı artışı sağladığı gözlemlenmiştir. Bu sonuçlara göre önerilen metrik ve metodun boyutsallık lanetini (küçük örnek eğitim boyutu sorunu) çözmek için potansiyel bir çözüm algoritması olduğu söylenebilir. Elde edilen maksimum FM artışları, DVVT için 0.133 ($L = 10$), TSDVM için 0.080 ($L = 3$) olarak, maksimum DSO artışları, DVVT için 13.94% ($L = 50$), TSDVM için 4.37% ($L = 10$) olarak elde edilmiştir. Botswana HS veri kümesi için önerilen yöntemin özellikle çok küçük örnek eğitim boyutlarında $L = 3, 6, 10$ daha etkili olduğu, eğitim boyutu arttıkça performans kazancında kısmen azalış yaşandığı görülmüştür.

Çizelge 6.14 Botswana veri seti için önerilen yöntemle FM ve DSO (%) skorlarında elde edilen performans artışları (klasik DVVT ve TSDVM’e göre)

Performans metriği	DVVT					TSDVM				
	Eğitim seti boyutu					Eğitim seti boyutu				
	3	6	10	20	50	3	6	10	20	50
FM	+0,085	+0,123	+0,133	+0,125	+0,110	+0,080	+0,034	+0,031	+0,030	+0,014
DSO	+4,36	+10,55	+12,57	+12,95	+13,94	+3,73	+3,92	+4,37	+3,64	+2,46

Botswana veri seti ile ilgili genel bir değerlendirme yapıldığında; önerilen metrik ile oluşturulan yöntemin özellikle çok küçük eğitim boyutlarında daha iyi bir performans sergilediği görülmüştür. Ayrıca, ÇA ve BE tabanlı yöntemlerde klasik sınıflandırıcılara göre iyi sonuçlar vermiştir.

6.5 Değerlendirme

Sınırlı eğitim örneği boyutunda HSG ile hedef tespiti gürbüz ve doğru bir teknik gerektirmektedir. Tek sınıf sınıflandırıcılar küçük eğitim boyutlarında zayıf genelleme (karasız olması) yapabilmesi nedeniyle, performansı arttırmak için birçok sınıflandırıcıların birleşimi (topluluk öğrenme yöntemi) tercih edilebilir. Bununla birlikte, iyi bir topluluk öğrenme yöntemi özellikle TSS'lerde her zaman kolay olmamaktadır. Uygun sınıflandırıcı birleştirme tekniğinin yanı sıra, sınıflandırıcılar arasındaki çeşitliliği arttırmak tüm TÖ yöntemlerinde ana kritik konu haline gelmiştir. Bu bölümde, HSG'de hedef tespit performansını özellikle çok küçük eğitim verisi boyutlarında iyileştirmek amacıyla yeni önerilen benzerlik (farklılık) metriği ile oluşturulan TÖ yöntemi sunulmuştur. Önerilen benzerlik metriği, topluluktaki her sınıflandırıcı arasındaki çeşitliliği ölçmek ve ölçüm değerlerini taban sınıflandırıcıları birleştirme sürecinde ağırlık vermek için kullanılmıştır. Yöntem farklı sensörlerden alınan üç gerçek hiperspektral veri kümesi üzerinde incelenmiştir. Yapılan uygulamalar sonucunda önerilen metriğin kıyaslama yaptığımız benzerlik/farklılık metriklerine ve klasik TSS'lara karşı etkinliğini özellikle küçük eğitim boyutlarında doğrulanmıştır.

SONUÇ VE ÖNERİLER

Uzaktan algılama alanında kullanılan HSG’de sınıflandırma ve hedef tespit problemlerinde performans iyileştirmesi hala üzerinde araştırma yapılan hassas ve önemli bir konudur. Hiperspektral verilerin yüksek boyutlu yapıda olması büyük miktarda verinin doğru işlenmesini zorlaştırmakta, ayrıca hedef tespit probleminde olduğu gibi sadece hedef sınıfa ait ve sınırlı eğitim verisine sahip olunması durumlarında işlemler daha da karmaşıklaşmaktadır.

Bu tezin temel amacı, hiperspektral görüntülerin sınıflandırılması/hedef tespit uygulamalarında yukarıda belirtilen problemlerin giderilmesi ve performans artışı sağlamak için topluluk öğrenme tabanlı etkin yöntemler ile bu yöntemlerdeki sınıflandırıcılar arasındaki çeşitliliği artırmak için yeni bir benzerlik/farklılık metriği önermektir. TÖ, birçok uygulama alanında sınıflandırma doğruluğunu geliştirme kabiliyeti kanıtlanmış istatistiksel bir tekniktir. Bununla birlikte HSG işlemlerinde TSS ile gürbüz ve güvenilir TÖ tekniği uygulanması kısıtlı ve zor bir işlem olabilmektedir. Bu tezde, başarı oranını artırmak ve sınıflandırıcıları daha kararlı hale getirebilmek için TÖ yönteminde;

- Sınıflandırıcılar arasında çeşitliliği artırmak,
- Veri birleştirme işlemi sırasında sınıflandırıcılara ağırlık atamak ve seçme işlemi yapmak,
- Ayrıca küçük eğitim verisi boyutlarında daha iyi sonuçlar elde etmek hedeflenmiştir.

Bu amaçlara yönelik olarak dördüncü bölümde, literatürde üzerinde fazla çalışma yapılmamış HSG işlemede TÖ tabanlı DVVT oluşturmayı hedefledik. DVVT, HSG’de sınıflandırma ve hedef tespit problemlerinde kullanılan sınır betimlemeli tek sınıf sınıflandırıcılardan birisidir. TÖ-DVVT oluşturulurken veri birleştirme safhasında

ağırlık atamak için her bir taban sınıflandırıcı sonuçları arasındaki korelasyon katsayılarını kullanmayı önerdik. Önerilen algoritmayı doğrulamak için üç farklı HS veri seti üzerinde denemeler yapılmış ve klasik DVVT'ye göre performans kıyaslaması yapılmıştır. Önerilen yöntem ile ortalama sınıflandırma performansında elde edilen iyileştirme DSO skorları bazında; KSC verisi için 2.07%, Botswana verisi için 4.2% ve Pavia university verisi için 2.64% olarak elde edilmiş olup önerilen korelasyon tabanlı TÖ yönteminin sınıflandırıcı performansını artırmada ve daha kararlı hale getirmede başarılı ve alternatif bir yöntem olduğu gözlemlenmiştir.

Beşinci bölümde, HS hedef tespit problemi için sınır tabanlı sınıflandırıcılar için önemli olan çekirdek fonksiyonu parametrelerini optimize etmeye çalışmadan sınıflandırıcı performansını artırmak ve bu durumu küçük eğitim seti boyutlarında da elde etmek üzerine odaklandık. Çekirdek fonksiyonları, verilerin doğrusal dağılımını sağlamak için orijinal veriyi daha yüksek boyutlu bir uzaya taşırlar. Ancak, uygun bir çekirdek fonksiyonu ile hassas parametrelerini bulmak zor ve zaman alan bir konu olarak karşımıza çıkmaktadır. Bu bölümde, çekirdek fonksiyonu parametresini optimize etmek yerine, birden fazla sınıflandırıcının farklı parametere değerlerine sahip çekirdek fonksiyonu kullanılarak eğitilmiş ve sonrasında her pikselin nihai etiket sonucu almak için sınıflandırıcı çıktılarını ağırlıksız/ağırlılı/seçmeli füzyon (birleştirme) kurallarına göre birleştiren yeni bir yöntem önerilmiştir. Bu yöntemde, birleştirme safhasında sınıflandırıcılara ağırlık atama ve sınıflandırıcı seçimi DSO skoru tabanlı algoritmalarla yapılmıştır. Önerilen algoritmaları doğrulamak için, iki HS veri seti üzerinde farklı büyüklüklerdeki eğitim veri setleri ile uygulamalı gerçekleştirilmiş ve klasik sınıflandırıcıya göre performans kıyaslaması yapılmıştır. Önerilen yöntemlerle elde edilen ortalama sınıflandırma performansı artışları DSO skorları bazında; DC Mall verisi için ağırlıklı oylama'da 4.76%, seçici ağırlıklı oylama'da 6.18%, salinas valley verisi için ağırlıklı oylama'da 4.67%, seçici ağırlıklı oylama'da 6.32% olarak elde edilmiştir. Ayrıca, çok küçük eğitim seti boyutunda bile ($L = 5$) yaklaşık 4%'lük yüksek bir performans kazanımı sağlanmıştır. Bu sonuçlara göre önerilen çekirdek parametresi değişimli TÖ modelinin hedef tespiti probleminde oldukça iyi bir performans artışı sağlayan yöntem olduğu gösterilmiştir.

Altıncı bölümde, TÖ yöntemi başarısı için gereken en önemli hususlardan birisi olan çeşitlilik (diversity) üzerine odaklanılmıştır. Veri birleştirmede sınıflandırıcılar arasındaki çeşitliliği oluşturarak performan artışı hedeflenmiştir. Çeşitliliği ölçmek için

literatürde önerilen birçok benzerlik/farklılık metrikleri var olmakla birlikte, amaca yönelik gürbüz ve uygun bir çeşitlilik ölçütü tanımlamak zor bir uğraş olabilmektedir. Bu çalışmada, HSG ile sınıflandırma ve hedef tespit amacıyla TÖ yönteminde kullanılabilecek yeni bir benzerlik/farklılık metriği önerilmiştir. Metrik, HS veri yapısını göz önüne alarak tanımlanmış ve TÖ'deki her bir taban sınıflandırıcının çeşitlilik seviyesini bulmak için kullanılmıştır. Önerdiğimiz metrik ile elde ettiğimiz farklılık değerlerini kullanarak ağırlık atama işlemleri yapılmıştır. Böylece, çeşitliliği yüksek olan sınıflandırıcılara veri birleştirme işlemi sırasında daha fazla ağırlık atayarak topluluktaki çeşitlilik artırılmıştır. Önerilen metrik ve algoritma üç farklı HS veri seti üzerinde uygulanmış ve geleneksel sınıflandırıcılar ile literatürde yaygın olarak kullanılan dört benzerlik/farklılık metriği ile uygulanan algoritmaya karşı performans karşılaştırması yapılmıştır. Ayrıca, farklı büyüklüklerdeki eğitim veri seti boyutları ile uygulamalar tekrarlanmıştır. Uygulamalar sonucunda aşağıdaki hususlar elde edilmiştir.

- Önerilen yeni metrik ile uygulanan TÖ yöntemi hiperspektral görüntüde tek sınıf sınıflandırma ve hedef tespiti problemlerinde klasik sınıflandırıcının performansını artırmış,
- Yeni metrik farklı eğitim seti büyüklüklerinde yaygın olarak bilinen metriklerle kıyasla daha iyi sonuçlar vermiş,
- Özellikle çok küçük eğitim örneği boyutlarında daha iyi performans artışları sağlanmıştır.

Özetlemek gerekirse bu tezde, özellikle küçük eğitim örneği boyutu koşulunda (KÖS problemi) HSG üzerinde hedef tespiti ve sınıflandırma performansını arttırmak için TÖ tabanlı yeni algoritmalar ve bu algoritmalarda kullanılmak üzere yeni bir çeşitlilik metriği önerilmiştir. Elde edilen sonuçlara göre, önerilen metrik ve yöntemlerin HSG problemlerinde performans artışı sağlamada ve sınıflandırıcıları daha kararlı hale getirmede başarılı ve alternatif olduğu gözlemlenmiştir. Bu araştırmada, HSG uygulamaları için önerilen algoritmaların ve özellikle yeni benzerlik metriğinin en önemli katkıları olduğu değerlendirilmektedir.

KAYNAKLAR

- [1] Zhang, L., Zhang, L., Tao, D., Huang, X. ve Du, B., (2014). “Hyperspectral Remote Sensing Image Subpixel Target Detection Based on Supervised Metric Learning”, *IEEE Transactions on Geoscience and Remote Sensing*, 52(8): 4955-4965.
- [2] Pu, H., Chen, Z., Wang, B. ve Jiang, G.M., (2014). “A Novel Spatial–Spectral Similarity Measure for Dimensionality Reduction and Classification of Hyperspectral Imagery”, *IEEE Transactions on Geoscience and Remote Sensing*, 52(11): 7008-7022.
- [3] Zhao, R., Du, B. ve Zhang, L., (2014). “A Robust Nonlinear Hyperspectral Anomaly Detection Approach”, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(4): 1227-1234.
- [4] Li, W., Du, Q. ve Zhang, B., (2015). “Combined Sparse and Collaborative Representation for Hyperspectral Target Detection”, *Pattern Recognition*, 48: 3904–3916.
- [5] Ghiyamat, A. ve Shafri, H.Z.M., (2010). “A Review on Hyperspectral Remote Sensing for Homogeneous and Heterogeneous Forest Biodiversity Assessment”, *International Journal of Remote Sensing*, 31(7): 1837–1856.
- [6] Wang, J., Brown, D. ve Bai, Y., (2014). “Investigating the Spectral and Ecological Characteristics of Grassland Communities Across an Ecological Gradient of the Inner Mongolian Grasslands with in Situ Hyperspectral Data”, *International Journal of Remote Sensing*, 35(20): 7179-7198.
- [7] Huang, H., Liu, L. ve Ngadi, M.O., (2014). “Recent Developments in Hyperspectral Imaging for Assessment of Food Quality and Safety”, *Sensors*, 14: 7248-7276.
- [8] Manolakis, D., Marden, D. ve Shaw, G.A., (2003). “Hyperspectral Image Processing for Automatic Target Detection Applications”, *Lincoln Laboratory Journal*, 14(1): 79-116
- [9] Imani, M. ve Ghassemian, H., (2014). “Feature Extraction Using Attraction Points for Classification of Hyperspectral Images in a Small Sample Size Situation”, *IEEE Geoscience and Remote Sensing Letters*, 11(11): 1986-1990.
- [10] Beaven, S.G, Stein, D. ve Hoff, L.E., (2000). “Comparison of Gaussian Mixture and Linear Mixture Models for Classification of Hyperspectral Data”, *IGARSS 2000, Honolulu, HI*, 1597-1599.

- [11] Tax, D., (2001). *One-Class Classification: Concept-Learning in the Absence of Counterexamples*, ASCI Dissertation Series, Delft University of Technology.
- [12] Banerjee, A., Burlina, P. ve Diehl, C., (2006). "A Support Vector Methods for Anomaly Detection in Hyperspectral Imagery", *IEEE Transactions on Geoscience and Remote Sensing*, 44(8): 2282–2291.
- [13] Perdisci, R., Gu, G. ve Lee, W., (2006). "Using an Ensemble of One-Class SVM Classifiers to Harden Payload-based Anomaly Detection Systems", *Sixth International Conference on Data Mining (ICDM'06)*, Hong Kong, 488-498.
- [14] Tax, D.M.J. ve Duin, R.P.W., (2004). "Support Vector Data Description", *Machine Learning*, 54(1): 45–66.
- [15] Zhihong, Z., Yun, F., Roisman, G.I., Wen, Z., Hu, Y. ve Huang, T.S., (2006). "One Class Classification for Spontaneous Facial Expression Analysis", *IEEE International Conference on Automatic Face and Gesture Recognition*, 10-12 April 2006, 281–286.
- [16] Ruirui, J., Ding, L., Min, W. ve Liu, J., (2008). "The Application of SVDD in Gene Expression Data Clustering", *2nd International Conference on Bioinformatics and Biomedical Engineering*, Shanghai, 371-374.
- [17] Bu, H., Wang, J. ve Huang, X., (2009). "Fabric Defect Detection Based on Multiple Fractal Features and Support Vector Data Description", *Engineering Applications of Artificial Intelligence*, 22: 224–235.
- [18] Xia, J., Chanussot, J., Du P. ve He, X., (2015). "Spectral–Spatial Classification for Hyperspectral Data Using Rotation Forests with Local Feature Extraction and Markov Random Fields", *IEEE Transactions on Geoscience and Remote Sensing*, 53(5): 2532-2546.
- [19] Zhang, L., Sun, Y., Meng, D. ve Li, X., (2010). "Anomaly Detection for Hyperspectral Imagery Based on Incremental Support Vector Data Description", *Multimedia Technology (ICMT), 2010 International Conference on*, Ningbo, 1-4.
- [20] Sakla, W., Chan, A., Ji, J. ve Sakla, A., (2011). "An SVDD-Based Algorithm for Target Detection in Hyperspectral Imagery", *IEEE Geoscience and Remote Sensing Letters*, 8(2): 384–388.
- [21] Cha, M., Kim, J.S. ve Baek, J., (2014). "Density Weighted Support Vector Data Description", *Expert Systems with Applications*, 41: 3343–3350.
- [22] Le, T., Tran, D. ve Ma, W., (2013). "Fuzzy Multi-Sphere Support Vector Data Description", J. Pei et al. (Eds.): *PAKDD 2013, Part II*, LNAI 7819, 570–581, Springer-Verlag Berlin Heidelberg.
- [23] Wang, Z., Gao, D. ve Pan, Z., (2010). "An Effective Support Vector Data Description with Relevant Metric Learning", L. Zhang, J. Kwok, and B.-L. Lu (Eds.): *ISNN 2010, Part II*, LNCS 6064, 42–51, Springer-Verlag Berlin Heidelberg.
- [24] Duan, X., Tian, Z., Ding, M. ve Zhao, W., (2013). "Registration of Remote-Sensing Images Using Robust Weighted Kernel Principal Component Analysis", *AEU - International Journal of Electronics and Communications*, 67(1): 20-28.

- [25] Chapelle, O., Vapnik, V., Bousquet, O. ve Mukherjee, S., (2002). “Choosing Multiple Parameters for Support Vector Machines”, *Machine Learning*, 46: 131–159.
- [26] Li, C.H., Ho, H.H., Liu, Y.L., Lin, C.T., Kuo, B.C. ve Taur, J.S., (2012). “An Automatic Method for Selecting the Parameter of the Normalized Kernel Function to Support Vector Machines”, *Journal of Information Science and Engineering*, 28(1): 1-15.
- [27] Gonen, M. ve Alpaydın, E., (2013). “Localized Algorithms for Multiple Kernel Learning”, *Pattern Recognition*, 46: 795–807.
- [28] Xia, J., Chanussot, J., Du, P. ve He, X., (2016). “Rotation-Based Support Vector Machine Ensemble in Classification of Hyperspectral Data with Limited Training Samples”, *IEEE Transactions on Geoscience and Remote Sensing*, 54(3): 1519-1531.
- [29] Yang, P., Yoo, P.D., Fernando, J., Zhou, B.B., Zhang, Z. ve Zomaya, A.Y., (2014). “Sample Subset Optimization Techniques for Imbalanced and Ensemble Learning Problems in Bioinformatics Applications”, *IEEE Transactions on Cybernetics*, 44(3): 445-455.
- [30] Kodovsky, J., Fridrich, J. ve Holub, V., (2012). “Ensemble Classifiers for Steganalysis of Digital Media”, *IEEE Transactions on Information Forensics and Security*, 7(2): 432-444.
- [31] Huang, X. ve Zhang, L., (2013). “An SVM Ensemble Approach Combining Spectral, Structural, and Semantic Features for the Classification of High-Resolution Remotely Sensed Imagery”, *IEEE Transactions on Geoscience and Remote Sensing* 51(1): 257-272.
- [32] Huang, X., Lu, Q. ve Zhang, L., (2014). “A Multi-Index Learning Approach for Classification of High-Resolution Remotely Sensed Images Over Urban Areas”, *ISPRS Journal of Photogrammetry and Remote Sensing*, 90: 36–48.
- [33] Kang, S., Cho, S. ve Kang, P., (2015). “Multi-Class Classification via Heterogeneous Ensemble of One-Class Classifiers”, *Engineering Applications of Artificial Intelligence*, 43: 35–43.
- [34] Wang, X.Y., Zhang, B.B. ve Yang, H.Y., (2013). “Active SVM-Based Relevance Feedback Using Multiple Classifiers Ensemble and Features Reweighting”, *Engineering Applications of Artificial Intelligence*, 26: 368–381.
- [35] Kang, S., Kang, P., Ko, T., Cho, S., Rhee, S.J. ve Yu, K.S., (2015). “An Efficient and Effective Ensemble Of Support Vector Machines For Anti-Diabetic Drug Failure Prediction”, *Expert Systems with Applications*, 42: 4265–4273.
- [36] Segui, S., Igual, L. ve Vitria, J., (2013). “Bagged One-Class Classifiers in the Presence of Outliers”, *International Journal of Pattern Recognition and Artificial Intelligence*, 27(5): 1-22.
- [37] Tai, X. ve Wang, L., (2014). “Develop an Ensemble Support Vector Data Description Method for Improving Invasive Tamarisk Mapping at Regional Scale”, *International Journal of Remote Sensing*, 35(19): 7030-7045.

- [38] Xing, H.J. ve Chen, X.F., (2012). “Selective Ensemble of Support Vector Data Descriptions for Novelty Detection”, J. Wang, G.G. Yen, and M.M. Polycarpou (Eds.): ISSN 2012, Part I, LNCS 7367, 468–477, Springer-Verlag Berlin Heidelberg.
- [39] Kuncheva, L.I. ve Rodriguez, J.J., (2014). “A Weighted Voting Framework for Classifiers Ensembles”, *Knowledge and Information Systems*, 38(2): 259-275.
- [40] Zhang, L. ve Zhou, W.D., (2011). “Sparse Ensembles Using Weighted Combination Methods Based on Linear Programming”, *Pattern Recognition*, 44: 97–106.
- [41] Shipp, C.A. ve Kuncheva, L.I., (2002). “Relationships Between Combination Methods and Measures of Diversity in Combining Classifiers”, *Information Fusion*, 3(2): 135-148.
- [42] Kuncheva, L.I., (2003). “Fuzzy Versus Nonfuzzy in Combining Classifiers Designed by Boosting”, *IEEE Transactions on Fuzzy Systems*, 11(6): 729-741.
- [43] Tumer, K. ve Ghosh, J., (1996). “Error Correlation and Error Reduction in Ensemble Classifiers”, *Connection Science*, 8(3/4): 385-404.
- [44] Chen, Y., Zhao, X. ve Lin, Z., (2014). “Optimizing Subspace SVM Ensemble for Hyperspectral Imagery Classification”, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(4): 1295-1305.
- [45] Xia, J., Falco, N., Benediktsson, J.A., Chanussot, J. ve Du, P., (2016). “Class-Separation-Based Rotation Forest for Hyperspectral Image Classification”, *IEEE Geoscience and Remote Sensing Letters*, 13(4): 584-588.
- [46] Kuncheva, L.I. ve Whitaker, C.J., (2003). “Measures of Diversity in Classifier Ensembles and Their Relationship with the Ensemble Accuracy”, *Machine Learning*, 51(2): 181–207.
- [47] Kuncheva, L.I., (2013). “A Bound on Kappa-Error Diagrams for Analysis of Classifier Ensembles”, *IEEE Transactions on Knowledge and Data Engineering*, 25(3): 494-501.
- [48] Hadjitodorov, S.T., Kuncheva, L.I. ve Todorova, L.P., (2006). “Moderate Diversity for Better Cluster Ensembles”, *Information Fusion*, 7(3): 264-275.
- [49] Hughes, G.F., (1968). “On the Mean Accuracy of Statistical Pattern Recognition”, *IEEE Transactions on Information Theory*, 14(1): 55–63.
- [50] Parhizkar, E. ve Abadi, M., (2015). “Beeowa: A Novel Approach Based On ABC Algorithm and Induced Owa Operators for Constructing One-Class Classifier Ensembles”, *Neurocomputing*, 166:367-381.
- [51] Guo, L., Zhao, L., Wu, Y., Li, Y., Xu, G. ve Yan, Q., (2011). “Tumor Detection in MR Images Using One-Class Immune Feature Weighted SVMs”, *IEEE Transactions on Magnetics*, 47(10): 3849-3852.
- [52] Scholkopf, B., Williamson, R.C., Smola, A. ve Taylor, J.S., (2000). “SV Estimation of a Distribution’s Support”, *Advances in Neural Information Processing Systems*, 12: 582-588.
- [53] Bilgin, G., Erturk, S. ve Yildirim, T., (2011). “Segmentation of Hyperspectral Images via Subtractive Clustering and Cluster Validation Using One-Class

- Support Vector Machines”, *IEEE Transactions on Geoscience and Remote Sensing*, 49(8): 2936-2944.
- [54] Vapnik, V.N., (1999). “An Overview of Statistical Learning Theory”, *IEEE Transactions on Neural Networks*, 10(5): 988-999.
- [55] Rokach, L., (2009). “Taxonomy for Characterizing Ensemble Methods in Classification Tasks: A Review and Annotated Bibliography”, *Computational Statistics & Data Analysis*, 53(12): 4046-4072.
- [56] Merkwirth, C., Mauser, H., Schulz-Gasch, T., Roche, O., Stahl, M. ve Lengauer, T., (2004). “Ensemble Methods for Classification in Cheminformatics”, *Journal of Chemical Information and Modeling*, 44(6): 1971-1978.
- [57] Tan, A.C., Gilbert, D. ve Deville, Y., (2003). “Multi-Class Protein Fold Classification Using a New Ensemble Machine Learning Approach”, *Genome Informatics*, 14: 206-217.
- [58] Moskovitch, R., Elovici, Y. ve Rokach, L., (2008). “Detection of Unknown Computer Worms Based on Behavioral Classification of the Host”, *Computational Statistics and Data Analysis*, 52 (9): 4544-4566.
- [59] Rokach, L., (2008). “Mining Manufacturing Data Using Genetic Algorithm-Based Feature Set Decomposition”, *International Journal of Intelligent Systems Technologies and Applications*, 4(1): 57-78.
- [60] Bruzzone, L., Cossu, R. ve Vernazza, G., (2004). “Detection of Land-Cover Transitions by Combining Multidate Classifiers”, *Pattern Recognition Letters*, 25(13): 1491-1500.
- [61] Tao, D., Tang, X., Li, X. ve Wu, X., (2006). “Asymmetric Bagging and Random Subspace for Support Vector Machines-Based Relevance Feedback in Image Retrieval”, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 28(7): 1088-1099.
- [62] Tukey, J.W., (1977). *Exploratory Data Analysis*, Addison-Wesley, Reading, MA.
- [63] Hansen, L.K. ve Salamon, P., (1990). “Neural Network Ensembles”, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 12(10): 993-1001.
- [64] Schapire, R.E., (1990). “The Strength of Weak Learnability”, *Machine Learning*, 5(2): 197-227.
- [65] Wolpert, D.H., (1992). “Stacked Generalization”, *Neural Networks*, 5: 241-259.
- [66] Freund, Y. ve Schapire, R.E., (1996). “Experiments with a New Boosting Algorithm”, *Machine Learning: Proceedings of the Thirteenth International Conference*, 325-332.
- [67] Breiman, L., (1996). “Bagging Predictors”, *Machine Learning*, 24(2): 123–140.
- [68] Ho, T.K., (1998). “Nearest Neighbors in Random Subspaces”, *Proceedings of the Second International Workshop on Statistical Techniques in Pattern Recognition*, Sydney, Australia, 13: 640-648.

- [69] Rodriguez, J.J., Kuncheva L.I. ve Alonso, C.J., (2006). "Rotation Forest: A New Classifier Ensemble Method", IEEE Transactions on Pattern Analysis and Machine Intelligence, 28(10): 1619-1630.
- [70] Li, P., (2006). Kernel Machines and Classifier Ensemble Learning for Biomedical Applications, A PhD thesis submitted to the Nanyang Technological University.
- [71] Kuncheva, L.I., (2002). "A Theoretical Study on Six Classifier Fusion Strategies" IEEE Transactions on Pattern Analysis and Machine Intelligence, 24(2): 281-286.
- [72] Brown, G., Wyatt, J., Harris R. ve Yao, X., (2005). "Diversity Creation Methods: A Survey and Categorisation", Information Fusion, 6(1): 5-20.
- [73] Jaccard, P., (1901). "Étude Comparative de la Distribution Florale Dans Une Portion Des Alpes Et Des Jura", Bull Soc Vandoise Sci Nat, 37: 547-579.
- [74] Jones, J.A., Harrold, M.J. ve Stasko, J., (2001). "Visualization of Test Information to Assist Fault Localization", The 24th International Conference on Software Engineering (ICSE'01), May 2001, 467-477.
- [75] Shi, J.Y., Yiu, S.M., Li, Y., Leung, H.C.M. ve Chin, F.Y.L., (2014). "Predicting Drug-Target Interaction for New Drugs Using Enhanced Similarity Measures and Super-Target Clustering" IEEE International Conference on Bioinformatics and Biomedicine (BIBM), 2014, Belfast, 45-50.
- [76] Hsiao, K.J., Xu, K.S., Calder, J. ve Hero, A.O., (2016) "Multicriteria Similarity-Based Anomaly Detection Using Pareto Depth Analysis", IEEE Transactions on Neural Networks and Learning Systems, 27(6): 1307-1321.
- [77] McNamee, R.C., (2013). "Can't See the Forest for the Leaves: Similarity and Distance Measures For Hierarchical Taxonomies with a Patent Classification Example", Research Policy, 42(4): 855-873.
- [78] Jiao, L., Tang, X., Hou, B. ve Wang, S., (2015). "SAR Images Retrieval Based on Semantic Classification and Region-Based Similarity Measure for Earth Observation", IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 8(8): 3876-3891.
- [79] Lu, J., Tan, Y.P., Wang G. ve Yang, G., (2013). "Image-to-Set Face Recognition Using Locality Repulsion Projections and Sparse Reconstruction-Based Similarity Measure", IEEE Transactions on Circuits and Systems for Video Technology, 23(6): 1070-1080.
- [80] El-Alfy, S.M., Abdel-Aal, R.E., Al-Khatib, W.G. ve Alvi, F., (2015). "Boosting Paraphrase Detection Through Textual Similarity Metrics with Abductive Networks", Applied Soft Computing, 26: 444-453.
- [81] Kuncheva, L.I., Skurichina, M. ve Duin, R.P.W., (2002). "An Experimental Study on Diversity for Bagging and Boosting with Linear Classifiers", Information Fusion, 3(4): 245-258.
- [82] Yule, G.U., (1900). "On the Association of Attributes in Statistics: With Illustrations from the Material of the Childhood Society", Philosophical Transactions of the Royal Society of London, 194: 257-319.

- [83] Giacinto, G. ve Roli, F., (2001). "Design of Effective Neural Network Ensembles for Image Classification", *Image and Vision Computing*, 19(9–10): 699-707.
- [84] Sokal, R.R. ve Michener, C.D., (1958). "A Statistical Method for Evaluating Systematic Relationships", *Univ. Kansas. Sci. Bull.*, 38: 1409-1438.
- [85] Kim, H.C., Pang, S., Je, H.M., Kim, D. ve Bang, S.Y., (2002). "Support Vector Machine Ensemble with Bagging", S.-W. Lee and A. Verri (Eds.): *SVM 2002*, LNCS 2388, 397–408, Springer-Verlag Berlin Heidelberg.
- [86] Gonen, M. ve Elpaz, E., (2011). "Multiple Kernel Learning Algorithms", *Journal of Machine Learning Research*, 12: 2211-2268.
- [87] Gu, Y., Wang, C., Wang, S. ve Zhang Y., (2011). "Kernel-Based Regularized-Angle Spectral Matching for Target Detection in Hyperspectral Imagery", *Pattern Recognition Letters*, 32: 114–119.
- [88] Weller-Fahy, D.J., Borghetti, B.J. ve Sodemann, A.A., (2015). "A Survey of Distance and Similarity Measures Used Within Network Intrusion Anomaly Detection", *IEEE Communications Surveys & Tutorials*, 17(1): 70-91.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Faruk Şükrü USLU
Doğum Tarihi ve Yeri : 03.03.1974, Bayburt, TÜRKİYE
Yabancı Dili : İngilizce
E-posta : fsuslu1974@yahoo.com

ÖĞRENİM DURUMU

Derece	Alan	Okul/Üniversite	Mezuniyet Yılı
Doktora	Elektronik ve Haberleşme Müh.	Yıldız Teknik Üniversitesi	--
Y. Lisans	İşletme	Ankara Üniversitesi	2007
Y. Lisans	Elektronik Müh.	ODTÜ	2001
Lisans	Elektronik Müh.	Ankara Üniversitesi	1993
Lise	Mimar Sinan Lisesi	Ankara	1989

İŞ TECRÜBESİ

Yıl	Firma/Kurum	Görevi
1994-	Hv.K.K.	Elektronik Müh.

YAYINLARI

Makale (SCI/SCI-Expanded)

1. 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.
2. Uslu, F.S., (2017). "Kernel parameter variation based selective ensemble support vector data description for oil spill detection on the ocean via hyperspectral imaging", *Journal of Applied Remote Sensing*, 11(3), 032404, doi:10.1117/1.JRS.11.032404.

Makale (Diğer Uluslararası Hakemli)

1. Uslu, F.S. ve Bal, A., (2016). "Mutual Information Based Ensemble Support Vector Data Description", *International Journal of Electrical, Electronics and Data Communication*, 4(2): 29-31.
2. 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.

Uluslararası Bildiri

1. Uslu, F.S., Binol, H. ve Bal, A., (2016). "Food Inspection Using Hyperspectral Imaging and SVDD", *Proc. SPIE 9864, Sensing for Agriculture and Food Quality and Safety VIII*, 98640N (May 17, 2016); doi:10.1117/12.2223938.
2. Uslu, F.S. ve Bal, A., (2016). "Mutual Information Based Ensemble Support Vector Data Description", *Proceedings of 2nd Research World International Conference*, New York, USA, 26th December 2015, 27-29.
3. Cukur, H., Binol, H., Uslu, F.S., Kalaycı, Y., ve Bal, A., (2015). "Cross Correlation Based Clustering for Feature Selection in Hyperspectral Imagery", *9th International Conference on Electrical and Electronics Engineering (ELECO)*, Bursa, 2015, 232-236.
4. Cukur, H., Binol, H., Uslu, F.S., ve Bal, A., (2015). "An Effective Band Selection Approach for Classification in Remote Sensing Imagery", *Proc. SPIE 9643, Image and Signal Processing for Remote Sensing XXI*, Toulouse, France, October 15, 2015, doi:10.1117/12.2197108.
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", *Proceedings of 2nd The IRES International Conference*, Berlin, Germany, 13th June 2015, 94-97.
6. Uslu, F.S., Binol, H., Bal, A., ve Cukur, H., (2015). "SVDD Fusion Based Classification in Hyperspectral Imagery", *2nd International Conference on Engineering and Natural Science (ICENS)*, July 22-24, 2015, Waseda University, Tokyo, Japan, 96-101.

7. Uslu, F.S., Bal, A., ve Binođ, H., (2015). “An Efficient Classifier Design for Remote Sensing Hyperspectral Imagery”, Recent Advances in Space Technologies (RAST), 2015 7th International Conference on, Istanbul, 2015, 207-210.

Ulusal Bildiri

1. Uslu, F.S. ve Bal, A., (2016). “Hiperspektral Görüntünlülerde Tek Sınıf Destek Vektör Makinası ve Destek Vektör Veri Tanımlaması Yöntemlerinin Performans Karşılaştırması”, UHAT-2015 / III. Ulusal Havacılık Teknolojisi ve Uygulamaları Kongresi 23-24 Ekim 2015, Konak, İZMİR, 42-48.
2. Uslu, F.S., (2015). “Solving Knapsack Problem with Genetic Algorithm”, 2015 23rd Signal Processing and Communications Applications Conference (SIU), Malatya, 2015, 1062-1065.

Proje

1. 013-2015, “Hiperspektral Görüntülerde Uzamsal Ve Spektral Öznitelikler Kullanarak Yüksek Hızda Hedef Tespiti Ve Sınıflama Yapan Algoritmaların Geliştirilmesi”, supported by TÜBİTAK. (TÜBİTAK - 112E207)