

TÜRKİYE CUMHURİYETİ
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

HİPERSPEKTRAL GÖRÜNTÜLERDE YARI GÜDÜMLÜ
ÖĞRENME TEKNİKLERİ

Muhammet Said AYDEMİR

DOKTORA TEZİ
Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisliği Programı

Danışman
Doç. Dr. Gökhan BİLGİN

Mayıs, 2019

TÜRKİYE CUMHURİYETİ
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

HİPERSPEKTRAL GÖRÜNTÜLERDE YARI GÜDÜMLÜ ÖĞRENME
TEKNİKLERİ

Muhammet Said AYDEMİR tarafından hazırlanan tez çalışması 21.05.2019 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı Bilgisayar Mühendisliği Programı **DOKTORA TEZİ** olarak kabul edilmiştir.

Doç. Dr. Gökhan BİLGİN
Yıldız Teknik Üniversitesi
Danışman

Jüri Üyeleri

Doç. Dr. Gökhan BİLGİN, Danışman
Yıldız Teknik Üniversitesi

Prof. Dr. Banu DİRİ, Üye
Yıldız Teknik Üniversitesi

Prof. Dr. Mustafa Ersel KAMAŞAK, Üye
İstanbul Teknik Üniversitesi

Dr. Öğr. Üyesi Erkan USLU, Üye
Yıldız Teknik Üniversitesi

Dr. Öğr. Üyesi Tolga ENSARİ, Üye
İstanbul Üniversitesi - Cerrahpaşa

Danışmanım Doç. Dr. Gökhan BİLGİN sorumluluğunda tarafımda hazırlanan Hiperspektral Görüntülerde Yarı GÜdümlü Öğrenme Teknikleri başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Muhammet Said AYDEMİR

İmza

Bu alıřma Yıldız Teknik Üniversitesi Bilimsel Arařtırma Projeleri Koordinatörlüğü Bölümü tarafından, 2016-04-01-DOP02 proje numarası ile desteklenmiştir.

*Bu tez alıřmasını verdikleri destekten ve gstermiř oldukları fedakarlıklarından dolayı
aileme ve eřime ithaf ediyorum...*

TEŞEKKÜR

Tez çalışmam sırasında kıymetli bilgi, birikim ve tecrübelerini esirgemedен vakit ayıran; yol gösterici olmasının yanı sıra verdiği manevi destekten dolayı danışman hocam Doç Dr. Gökhan BİLGİN' e sonsuz teşekkürlerimi borç bilirim. Tez çalışmam sırasından bilgilerini ve fikirlerini esirgemeyen ve her zaman destekleyici bir şekilde davranan izleme jürilerim Prof. Dr. Banu DİRİ ve Prof. Dr. Mustafa Ersel KAMAŞAK hocalarıma teşekkür ederim.

Lisans, yüksek lisans ve doktora hayatım boyunca hayatıma kattıkları değerlerden, bilgi, tecrübe ve anlayıştan dolayı Yıldız Teknik Üniversitesi Bilgisayar Mühendisliği bölümündeki tüm hocalarıma teşekkür ederim. Çalışmalarım boyunca yardımını ve desteğini hiç esirgemeyen değerli hocam Dr. Öğr. Üyesi Erkan USLU' ya teşekkürü bir borç bilirim.

Çalışmalarım ve öğrenim hayatım boyunca maddi ve manevi destekleriyle beni hiçbir zaman yalnız bırakmayan annem Perihan AYDEMİR'e, babam Vedat AYDEMİR' e, abim Hüsnü AYDEMİR' e sonsuz teşekkürler ederim. Tez çalışmalarım sırasında yaptığı fedakarlıklardan, göstermiş olduğu destek ve anlayıştan dolayı eşim Dilek AYDEMİR' e ayrıca sonsuz teşekkür ederim.

Muhammet Said AYDEMİR

İÇİNDEKİLER

SİMGE LİSTESİ	ix
KISALTMA LİSTESİ	xi
ŞEKİL LİSTESİ	xiii
TABLO LİSTESİ	xiv
ÖZET	xviii
ABSTRACT	xxi
1 Giriş	1
1.1 Literatür Özeti	1
1.2 Kullanılmakta Olan Hiperspektral Algılayıcılar	14
1.3 Tezin Amacı	17
1.4 Hipotez	18
1.4.1 Temel Artımsal Yarı-Güdümlü Öğrenme	19
1.4.2 Graf Tabanlı Yarı-Güdümlü Öğrenme	19
1.4.3 Derin Öğrenme Tabanlı Yarı-Güdümlü Öğrenme	19
2 Hiperspektral Veri Kümeleri	21
2.1 Rosis Pavia Üniversitesi Veri Kümesi	21
2.2 HYDICE DC Mall Veri Kümesi	22
2.3 Aviris Indian Pines Veri Kümesi	24
2.4 Aviris Salinas Veri Kümesi	25
2.5 Pavia Center Veri Kümesi	27
3 Temel Artımsal Yarı-Güdümlü Öğrenme	29
3.1 Yarı-Güdümlü Öğrenme	29
3.1.1 Birinci Yarı-Güdümlü Öğrenme Yaklaşımı	29
3.1.2 İkinci Yarı-Güdümlü Öğrenme Yaklaşımı	30
3.1.3 Üçüncü Yarı-Güdümlü Öğrenme Yaklaşımı	30
3.1.4 Dördüncü Yarı-Güdümlü Öğrenme Yaklaşımı	32

3.1.5	Beşinci Yarı-Güdümlü Öğrenme Yaklaşımı	32
3.2	DVM ve Seyrek Öğrenmenin Birleştirilmesi ile Sınıflandırma	32
3.3	DeneySEL Sonuçlar	35
3.3.1	Birinci Yaklaşım Sonuçları	36
3.3.2	İkinci Yaklaşım Sonuçları	39
3.3.3	Üçüncü Yaklaşım Sonuçları	40
3.3.4	Dördüncü Yaklaşım Sonuçları	42
3.3.5	Beşinci Yaklaşım Sonuçları	43
3.4	Sonuç ve Öneriler	43
4	Graf Tabanlı Yarı-Güdümlü Öğrenme	45
4.1	Yarı-Güdümlü Öğrenme	45
4.1.1	Birinci Yarı-Güdümlü Öğrenme Yaklaşımı (K-ortalamlar Kümeleme)	46
4.1.2	İkinci Yarı-Güdümlü Öğrenme Yaklaşımı (Eksiltici Kümeleme)	47
4.2	DVM ve Seyrek Öğrenmenin Birleştirilmesi ile Sınıflandırma	47
4.3	Derin Öğrenme, DVM ve Seyrek Öğrenmenin Birleştirilmesi ile Sınıflandırma	49
4.4	DVM ve Seyrek Öğrenmenin Etiket Puanlamasıyla Birleştirilmesi ile Sınıflandırma	52
4.5	Tüm Verinin Graf Tabanlı Sınıflandırılması	52
4.6	DeneySEL Sonuçlar	54
4.6.1	DVM ve Seyrek Öğrenmenin Birleştirilmesi ile Sınıflandırma Sonuçları	55
4.6.2	Derin Öğrenme, DVM ve Seyrek Öğrenmenin Birleştirilmesi ile Sınıflandırma Sonuçları	61
4.6.3	DVM ve Seyrek Öğrenmenin Etiket Puanlamasıyla Birleştirilmesi ile Sınıflandırma	71
4.6.4	Tüm Verinin Graf Tabanlı Sınıflandırılması	73
4.7	Sonuç ve Öneriler	77
5	Derin Öğrenme Tabanlı Yarı-Güdümlü Öğrenme	81
5.1	Derin Öğrenme Tabanlı Öznitelik Çıkarma Yapısı	82
5.1.1	Piksel Vektörlerinin İki Boyutlu Görüntülere Dönüşümü	82
5.1.2	Derin Model Ağı Tasarımı ve Kullanımı	83
5.2	Yarı-Güdümlü Öğrenme ve Sınıflama	84
5.3	DeneySEL Sonuçlar	88
5.4	Sonuç ve Öneriler	101
6	Sonuç ve Öneriler	103

A Detaylı Sınıflama Sonuçları	106
Kaynaklar	202
Tezden Üretilmiş Yayınlar	213

SİMGELİSTESİ

A	Seyrek Gösterim Sözlüğü
a^c	c. Sınıfa ait Seyrek Gösterim Alt Sözlük
C	Etiketli Örnekler için Ceza Katsayısı
C^*	Etiketsiz Örnekler için Ceza Katsayısı
c	c Sınıfı
e	Euler Sabiti
$f(x)$	Yoğunluk Fonksiyonu
h	Pencere Yarıçapı
$J(\theta)$	Ceza Fonksiyonu
$K(x)$	Çekirdek Fonksiyonu
k	Pencere Büyüklüğü
$L1$	Manhattan Distance
$L2$	Euclidean Distance
M	Boyut Sayısı
$M(x)$	Yoğunluk Potansiyeli
N_c	c Sınıflı Eğitim Kümesi
n	Veri Kümesindeki Örnek Sayısı
W	Seyrek Gösterim Vektörü
w^c	c. Sınıfa Ait Seyrek Gösterim Vektörü
$\hat{w}^c$	c. Sınıfa Ait Optimum Seyrek Gösterim Vektörü
x_i	i. Girdi Örneği
x_i^{max}	En Yüksek Potansiyele Sahip i. Örnek
x_j	j. Girdi Örneği

$\mathcal{Y}_L$	Etiketli Örnekler
$\mathcal{Y}_U$	Etiketsiz Örnekler
$\mathcal{Y}_i$	i. Örneğin Sınıf Bilgisi
ϵ	Seyrek Gösterim Hatası
ϵ^c	c. Sınıfa Ait Seyrek Gösterim Hatası
σ	Geri Çatma Hata Eşik Değeri
$\nabla f(x)$	Yoğunluk Fonksiyonu Değişimi

KISALTMA LİSTESİ

AVIRIS	Airborne Visible / Infrared Imaging Spectrometer
BBA	Bağımsız Bileşen Analizi
ckSRC	cluster-kernel Sparse Representation Classifier
CNN	Convolutional Neural Network
DL	Deep Learning
DLR	Deutsches Zentrum für Luft- und Raumfahrt
DVM	Destek Vektör Makineleri
EK	Eksiltici Kümeleme
EM	Expectation Maximization
ESA	European Space Agency
FDA	Fisher Discriminant Analysis
GMM	Gaussian Mixture Model
GPU	Graphics Processing Unit
HYDICE	Hyperspectral Digital Imagery Collection Experiment
KMC	K-Means Clustering
k-NN	k-Nearest Neighbour
LDA	Linear Discriminant Analysis
LLE	Local Linear Embedding
LORSAL	Logistic Regression via Variable Splitting and Augmented Lagrangian
LWIR	Long Wave Infrared
MIR	Mid-Infrared
MWIR	Mid-Wave Infrared
NASA	National Aeronautics and Space Administration

NIR	Near Infrared
PCA	Principle Component Analysis
PSO	Particle Swarm Optimization
RBF	Radial Basis Function
RCA	Relevant Component Analysis
RCNN	Recurrent Convolutional Neural Networks
RNN	Recurrent Neural Network
ROSIS	Reflective Optics System Image Spectrometer
RPN	Region Proposal Network
SC	Subtractive Clustering
SGS	Seyrek Gösterim Sınıflayıcısı
SMLR	Sparse Multinomial Logistic Regression
SMLFDA	Semi Supervised Manifold Local Fisher Discriminant Analysis
SRC	Sparse Representation Classifier
S^2DRpc	Semi-Supervised Dimensionality Reduction with pairwise constraints
SSL	Semi-Supervised Learning
SSLE	Semi-Supervised Local Embedding
S^2LFDA	Semi-Supervised Local Fisher Discriminant Analysis
S^2MLR	Soft-Sparse Multinomial Logistic Regression
S^2PPCA	Semi-Supervised Probabilistic Principal Component Analysis
S^3RC	Semi-Supervised Sparse Representation Classifier
SOM	Self Organizing Maps
SUNSAL	Spectral Unmixing by Splitting and Augmented Lagrangian
SWIR	Short Wave Infrared
SVM	Support Vector Machine
TIR	Thermal Infrared
VIS/NIR	Visible Near Infrared
YGÖ	Yarı-Güdümlü Öğrenme
YSA	Yapay Sinir Ağları

ŞEKİL LİSTESİ

Şekil 1.1	Elektromanyetik spektrum bölgesi [1]	2
Şekil 1.2	Uzaktan algılama teknolojileri spektrum karakteristikleri [1]	3
Şekil 1.3	Farklı spektrumlarda atmosferik etki	4
Şekil 2.1	Rosis Pavia Üniversitesi verisi (a) yapay renkli görüntü (b) eğitim örnekleri (c) test örnekleri	22
Şekil 2.2	HYDICE DC Mall verisi (a) yapay renkli görüntü (b) yer-gerçekliği görüntüsü	23
Şekil 2.3	Aviris Indian Pines verisi (a) Görüntü uzayında RGB üç kanal yapay görüntü (b) Kesin referans haritası	25
Şekil 2.4	Salinas verisi (a) Görüntü uzayında RGB üç kanal yapay görüntü (b) Kesin referans haritası	26
Şekil 2.5	Pavia Center verisi (a) Görüntü uzayında RGB üç kanal yapay görüntüsü (b) Kesin referans haritası	28
Şekil 3.1	Seyrek gösterim	33
Şekil 4.1	Genel sistem yapısı	46
Şekil 4.2	Genel sistem yapısı	49
Şekil 4.3	Graf tabanlı genel sistem akışı	53
Şekil 5.1	Piksel vektörünün iki boyutlu görüntüye dönüşümü	82
Şekil 5.2	Piksel küpünün iki boyutlu görüntüye dönüşümü	83
Şekil 5.3	Kullanılan derin ağ yapısı	84
Şekil 5.4	DBscan çalışma prensibi	86
Şekil 5.5	TSVM çalışma prensibi	87

TABLO LİSTESİ

Tablo 1.1	Uydu üzerindeki hiperspektral algılayıcılar [1]	14
Tablo 1.2	Hava aracı üzerindeki hiperspektral algılayıcılar [1]	14
Tablo 2.1	Rosis Pavia Üniversitesi eğitim ve test örnekleri bilgileri	21
Tablo 2.2	HYDICE DC Mall etiketli örnek bilgileri	23
Tablo 2.3	Indian Pines verisi etiketli örnek bilgileri	24
Tablo 2.4	Salinas verisi etiketli örnek bilgileri	26
Tablo 2.5	Rosis Pavia Center verisi etiketli örnek bilgileri	27
Tablo 3.1	Farklı örnek sayıları için YGÖ başarımı (%)	36
Tablo 3.2	Farklı örnek sayıları için sınıflama başarımı sonuçları (%)	37
Tablo 3.3	BBA ile farklı örnek sayıları için sınıflama başarımı sonuçları (%) .	37
Tablo 3.4	Bant seçimi sonrası farklı örnek sayıları için sınıflama başarımı sonuçları (%)	38
Tablo 3.5	Bant seçimi ve BBA sonrası farklı örnek sayıları için sınıflama başarımı sonuçları (%)	38
Tablo 3.6	Farklı örnek sayıları için k-ortalamlar ile YGÖ başarımı sonuçları (%)	39
Tablo 3.7	K-ortalamlar kümeleme ile farklı örnek sayıları için sınıflama başarımı sonuçları (%)	40
Tablo 3.8	Farklı örnek sayıları için eksiltici kümeleme ile YGÖ başarımı sonuçları (%)	40
Tablo 3.9	Eksiltici kümeleme ile farklı örnek sayıları için sınıflama başarımı sonuçları (%)	40
Tablo 3.10	Farklı örnek sayıları için eksiltici kümeleme ile YGÖ başarımı sonuçları (%)	41
Tablo 3.11	Farklı örnek sayıları için sınıflama başarımı sonuçları (%)	41
Tablo 3.12	Farklı örnek ve küme sayıları için YGÖ başarımı sonuçları (%) . . .	42
Tablo 3.13	Farklı örnek sayıları için sınıflama başarımı sonuçları (%)	42
Tablo 3.14	YGÖ Yaklaşım-1 ile etiketlenmiş farklı başlangıç örnek sayıları için YGÖ başarımı sonuçları (%)	43
Tablo 3.15	YGÖ Yaklaşım-1 ile etiketlenmiş farklı başlangıç örnek sayıları için sınıflama başarımı sonuçları (%)	43

Tablo 4.1	K-ortalamalar kümeleme ile alınan YGÖ, DVM, ÇSGS ve birleştirilmiş sistem başarımı sonuçları (DC Mall Hiperpektral Sahnesi) (%) . .	55
Tablo 4.2	FKT tabanlı yapılan çalışma [153] ile alınan başarım sonuçları (DC Mall Hiperpektral Sahnesi) (%)	56
Tablo 4.3	K-ortalamalar kümeleme ile alınan YGÖ, DVM, ÇSGS ve birleştirilmiş sistem başarımı sonuçları (Pavia Üniversitesi Hiperpektral Sahnesi) (%)	57
Tablo 4.4	SSNN tabanlı yapılan çalışma [154] ile alınan başarım sonuçları (Pavia Üniversitesi Hiperpektral Sahnesi) (%)	57
Tablo 4.5	Eksiltici kümeleme ile alınan YGÖ, DVM, ÇSGS ve birleştirilmiş sistem başarımı sonuçları (DC Mall Hiperpektral Sahnesi) (%) . .	58
Tablo 4.6	FKT tabanlı yapılan çalışma [153] ile alınan başarım sonuçları (DC Mall Hiperpektral Sahnesi) (%)	59
Tablo 4.7	Eksiltici kümeleme ile alınan YGÖ, DVM, ÇSGS ve birleştirilmiş sistem başarımı sonuçları (Pavia Üniversitesi Hiperpektral Sahnesi) (%)	60
Tablo 4.8	SSNN tabanlı yapılan çalışma [154] ile alınan başarım sonuçları (Pavia Üniversitesi Hiperpektral Sahnesi) (%)	60
Tablo 4.9	K-ortalamalar kümeleme ile alınan YGÖ, DVM, ÇSGS, birleştirilmiş sistem, DNN ve DNN eklenmiş birleştirilmiş sistem başarımı sonuçları (Pavia Üniversite Hiperpektral Sahnesi) (%)	62
Tablo 4.10	SSNN tabanlı yapılan çalışma [154] ile alınan başarım sonuçları (Pavia Üniversitesi Hiperpektral Sahnesi) (%)	62
Tablo 4.11	K-ortalamalar kümeleme ile alınan YGÖ, DVM, ÇSGS ve birleştirilmiş sistem başarımı sonuçları (Aviris Indian Pines Hiperpektral Sahnesi – 16 Sınıf) (%)	63
Tablo 4.12	K-ortalamalar kümeleme ile alınan YGÖ, DVM, ÇSGS ve birleştirilmiş sistem başarımı sonuçları (Aviris Indian Pines Hiperpektral Sahnesi – 9 Sınıf) (%)	65
Tablo 4.13	K-ortalamalar kümeleme ile alınan YGÖ, DVM, derin sınıflayıcı ve birleştirilmiş sistem başarımı sonuçları (Aviris Salinas Hiperpektral Sahnesi) (%)	66
Tablo 4.14	Eksiltici kümeleme ile alınan YGÖ, DVM, ÇSGS, birleştirilmiş sistem, DNN ve DNN eklenmiş birleştirilmiş sistem başarımı sonuçları (Pavia Üniversitesi Hiperpektral Sahnesi) (%)	67
Tablo 4.15	SSNN tabanlı yapılan çalışma [154] ile alınan başarım sonuçları (Pavia Üniversitesi Hiperpektral Sahnesi) (%)	67

Tablo 4.16 Eksiltici kümeleme ile alınan YGÖ, DVM, ÇSGS ve birleştirilmiş sistem başarımı sonuçları (Aviris Indian Pines Hiperspektral Sahnesi – 16 Sınıf) (%)	68
Tablo 4.17 Eksiltici kümeleme ile alınan YGÖ, DVM, ÇSGS ve birleştirilmiş sistem başarımı sonuçları (Aviris Indian Pines Hiperspektral Sahnesi – 9 Sınıf) (%)	68
Tablo 4.18 Eksiltici kümeleme ile alınan YGÖ, DVM, derin sınıflayıcı ve birleştirilmiş sistem başarımı sonuçları (Aviris Salinas Hiperspektral Sahnesi) (%)	69
Tablo 4.19 K-ortalamlar ve eksiltici kümeleme ile alınan YGÖ eğitim kümesi başarım sonuçları (DC Mall ve Pavia Üniversite Hiperspektral Sahnesi) (%)	71
Tablo 4.20 K-ortalamlar kümeleme ile alınan DVM, ÇSGS ve birleştirilmiş sistem başarımı sonuçları (DC Mall) (%)	72
Tablo 4.21 Eksiltici kümeleme ile alınan DVM, ÇSGS ve birleştirilmiş sistem başarımı sonuçları (DC Mall) (%)	73
Tablo 4.22 K-ortalamlar kümeleme ile alınan DVM, ÇSGS ve birleştirilmiş sistem başarımı sonuçları (Pavia Üniversitesi) (%)	74
Tablo 4.23 Eksiltici kümeleme ile alınan DVM, ÇSGS ve birleştirilmiş sistem başarımı sonuçları (Pavia Üniversitesi) (%)	75
Tablo 4.24 Standart k-ortalamlar, modifiye k-ortalamlar ve eksiltici kümeleme ile alınan sistem başarımı sonuçları (Indian Pines – 16 sınıf) (%)	76
Tablo 4.25 Standart k-ortalamlar, modifiye k-ortalamlar ve eksiltici kümeleme ile alınan sistem başarımı sonuçları (Indian Pines – 9 sınıf) (%)	78
Tablo 4.26 Modifiye k-ortalamlar ve eksiltici kümeleme ile alınan sistem başarımı sonuçları (Pavia Üniversite) (%)	79
Tablo 5.1 Pavia Üniversite verisi için farklı etiketli örnek sayıları için 1x1 pencere boyutu için eğitim kümesi sınıflama sonuçları (%)	91
Tablo 5.2 Pavia Üniversite verisi için farklı etiketli örnek sayıları için 3x3 pencere boyutu için eğitim kümesi sınıflama sonuçları (%)	92
Tablo 5.3 Pavia Üniversite verisi için farklı etiketli örnek sayıları için 5x5 pencere boyutu için eğitim kümesi sınıflama sonuçları (%)	92
Tablo 5.4 Pavia Üniversite verisi için farklı etiketli örnek sayıları için 7x7 pencere boyutu için eğitim kümesi sınıflama sonuçları (%)	93
Tablo 5.5 Pavia Üniversite verisi için farklı etiketli örnek sayıları için 1x1 pencere boyutu için tüm etiketsiz örneklerin sınıflama sonuçları (%)	93

Tablo 5.6	Pavia Üniversite verisi için farklı etiketli örnek sayıları için 3x3 pencere boyutu için tüm etiketsiz örneklerin sınıflama sonuçları (%)	94
Tablo 5.7	Pavia Üniversite verisi için farklı etiketli örnek sayıları için 5x5 pencere boyutu için tüm etiketsiz örneklerin sınıflama sonuçları (%)	94
Tablo 5.8	Pavia Üniversite verisi için farklı etiketli örnek sayıları için 7x7 pencere boyutu için tüm etiketsiz örneklerin sınıflama sonuçları (%)	95
Tablo 5.9	Indian Pines verisi için farklı etiketli örnek sayıları için 1x1 pencere boyutu için eğitim kümesi sınıflama sonuçları (%)	96
Tablo 5.10	Indian Pines verisi için farklı etiketli örnek sayıları için 3x3 pencere boyutu için eğitim kümesi sınıflama sonuçları (%)	96
Tablo 5.11	Indian Pines verisi için farklı etiketli örnek sayıları için 5x5 pencere boyutu için eğitim kümesi sınıflama sonuçları (%)	97
Tablo 5.12	Indian Pines verisi için farklı etiketli örnek sayıları için 7x7 pencere boyutu için eğitim kümesi sınıflama sonuçları (%)	97
Tablo 5.13	Indian Pines verisi için farklı etiketli örnek sayıları için 1x1 pencere boyutu için tüm etiketsiz örneklerin sınıflama sonuçları (%)	98
Tablo 5.14	Indian Pines verisi için farklı etiketli örnek sayıları için 3x3 pencere boyutu için tüm etiketsiz örneklerin sınıflama sonuçları (%)	98
Tablo 5.15	Indian Pines verisi için farklı etiketli örnek sayıları için 5x5 pencere boyutu için tüm etiketsiz örneklerin sınıflama sonuçları (%)	99
Tablo 5.16	Indian Pines verisi için farklı etiketli örnek sayıları için 7x7 pencere boyutu için tüm etiketsiz örneklerin sınıflama sonuçları (%)	99
Tablo A.1	Pavia Üniversite veri kümesi için farklı etiketli örnek sayıları ve farklı pencere boyutları için tüm etiketsiz örneklerin SVM ve TSVM ile detaylı sınıflama sonuçları	106
Tablo A.2	Indian Pines veri kümesi için farklı etiketli örnek sayıları ve farklı pencere boyutları için tüm etiketsiz örneklerin SVM ve TSVM ile detaylı sınıflama sonuçları	130
Tablo A.3	Pavia Üniversite veri kümesi için farklı etiketli örnek sayıları ve farklı pencere boyutları için tüm etiketsiz örneklerin S^3RC ile detaylı sınıflama sonuçları (%)	143
Tablo A.4	Indian Pines veri kümesi için farklı etiketli örnek sayıları ve farklı pencere boyutları için tüm etiketsiz örneklerin S^3RC ile detaylı sınıflama sonuçları	182

Hiperspektral Görüntülerde Yarı GÜdümlü Öğrenme Teknikleri

Muhammet Said AYDEMİR

Bilgisayar Mühendisliği Anabilim Dalı
Doktora Tezi

Danışman: Doç. Dr. Gökhan BİLGİN

Uzaktan algılama yöntemleri, algılama için sinyal gönderip göndermemelerine göre aktif ve pasif olarak iki alt başlıkta incelenmektedir. Pasif uzaktan algılama yöntemleri arasında yer alan hiperspektral görüntüleme son yıllarda gelişen görüntüleme teknolojisiyle araştırmacılar tarafından üzerinde yoğun olarak çalışılan bir alandır. Hiperspektral görüntüler, elektromanyetik spektrumda görünür bölgeden kızılötesi bölgeye kadar olan spektrumda spektral bantlara sahiptir. Hiperspektral görüntüleme kendisinden bir önceki teknoloji olan multispektral görüntülemeye göre daha fazla bant sayısına sahiptir. Multispektral görüntüler 4 ila 10 arasında spektral bantlara sahipken, hiperspektral görüntüler yüzün üzerinde bantlara sahiptir. Hiperspektral görüntüler, sivil ve askeri alanlarda birçok uygulamada kullanılmaktadır, çünkü hiperspektral görüntülerde her piksel ifade ettiği bölgenin neredeyse sürekli sinyal bilgisini elde etmeye olanak sağlar.

Hiperspektral görüntülerin uçak ve uydular ile elde edilmesinden dolayı algılayıcı ve algılanan madde arasında atmosfer tabakası bulunmaktadır. Bu nedenle, hiperspektral görüntülerde atmosferik etkilerden gürültü oluşmaktadır. Oluşan bu etkiler bazı bantlarda diğer bantlara oranla daha fazla etkiye sahiptirler. Bu nedenle hiperspektral görüntülerde bazı bantlar sağlayıcı tarafından atılmaktadır. Bunun yanında uygulama alanlarına göre farklılık gösterse de, hiperspektral görüntüler üzerinde yapılacak analiz işlemlerinden önce bir çok çalışmada çeşitli gürültü giderimi yöntemleri uygulanmaktadır. Bu tez çalışmasında da temel bileşen analizi ve bağımsız bileşen analizi uygulanarak bu gürültü etkisinin giderilmesi hedeflenmiştir.

Veri etiketleme diğer alanlarda olduğu gibi hiperspektral görüntüleme alanında da zaman ve iş gücü açısından maliyetli bir işlemdir. Bu nedenle makine öğrenmesi alanında araştırmacılar az sayıdaki etiketli örnekle, görüntü analizi yapmayı hedeflemektedirler. Bunun için ortaya atılan yöntemlerin genel adına da yarı-güdümlü öğrenme ismi verilmiştir. Yarı-güdümlü öğrenme yapısı nedeniyle melez bir öğrenme şeklidir. Etiket bilgisinin kullanılmadığı eğitici/süzgümsüz kümeleme yöntemleriyle, etiket bilgisinin kullanıldığı eğitici/güdümlü sınıflama yöntemlerinin arasındaki yöntemlerdir. Yarı-güdümlü öğrenme yöntemleri hem etiketli hem de etiketsiz veri bilgilerini kullanarak az sayıdaki etiketli örnekle hedefine ulaşmayı amaçlamaktadırlar. Bu tez çalışmasının temel amacı hiperspektral görüntülerin az sayıdaki etiketli örnekle yarı-güdümlü olarak sınıflandırılmasıdır.

Yarı-güdümlü öğrenme yöntemleri temel olarak iki aşamadan oluşmaktadır. Bunlardan ilki etiketli örnekleri seçimi, ikinci ise bu örneklerin etiketlenmesidir. Etiketleme süreci kadar etiketli örnek seçimi de önemlidir. Tez çalışmasının ilk bölümünde artımsal bir model olan kendi kendine öğrenme yöntemiyle yarı-güdümlü öğrenme uygulanmıştır. Burada etiketli örnek seçimi k-ortalamlar ve yarı-güdümlü öğrenme literatürde ilk defa uygulanan eksiltici kümeleme ile gerçekleştirilmiştir. Temel amaç en çok fayda/bilgi sağlayacak örneklerin seçilmesidir. İkinci aşama olan etiketsiz verilerin etiketlenmesinde ise artımsal bir model temel alınmıştır. Yarı-güdümlü olarak etiketlenen eğitim kümesinin ardından test kümesi çekirdek destek vektör makineleri ve çekirdek seyrek gösterim sınıflayıcısı gibi iki farklı güdümlü öğrenme yöntemiyle sınıflandırılmıştır. Bu sınıflandırıcı sonuçları karar aşamasında çeşitli şekillerde birleştirilerek sistem sonucu elde edilmiştir. Ayrıca bu bölümde çeşitli öznelitek seçim ve çıkarım yöntemleri uygulanarak sistem başarımına etkileri nesnel olarak gözlemlenmiştir.

Tez çalışmasının diğer bölümünde yarı-güdümlü öğrenme yöntemlerinin bir diğer çeşidi olan graf-tabanlı bir sistem önerilmiştir. Bu yapıda eğitim verisi veya tüm veriler bir graf üstüne yerleştirilerek aşama aşama etiketleme işlemi gerçekleştirilmektedir. Graf tabanlı yapıda komşu piksellerin de işin içine katılmasıyla uzamsal bilgi kullanılmıştır. Grafta sadece eğitim örnekleri kullanıldıysa test örnekleri yine farklı sınıflayıcılar ile sınıflanarak sınıflama sonuçları karar seviyesinde birleştirilmiştir. Bu bölümde, derin öğrenme tabanlı sınıflandırıcı, sınıflandırıcılara dahil edilmiştir ve sınıflandırma sonuçları karar aşamasında eklenmiştir. Ayrıca graf tabanlı yapının hesaplama işlemleri grafik işleme ünitesine aktarılmıştır. Bu sayede eğitim ve test örneklerinin tamamının graf tabanlı sistem ile etiketlenmesine olanak sağlanmıştır. İki farklı çözümün sonuçları ve literatürde ön plana çıkan çalışmaların sonuçları karşılaştırılmıştır.

1980' li yıllarda ortaya çıkan yapay sinir ağı teknolojisinin gelişmesiyle derin sinir ağı olarak tekrar ortaya çıkmıştır, ve diğer makine öğrenmesi yöntemleriyle elde edilemeyen başarımlara ulaşılmasına imkan sağlamıştır. Tez çalışmasının son bölümünde derin öğrenme tabanlı bir sistem önerilmiştir. Önerilen sistem temel olarak aynı özelliklere sahip hiperspektral veri kümeleri için tek bir derin modelin eğitilmesini ve diğer veri kümelerinin bu modeli kullanarak öznitelik çıkarım işlemlerini gerçekleştirmesini hedeflemektedir. Sistemde öncelikle hiperspektral görüntülerin derin öğrenme modellerine girdi olabilmesi için yeni bir veri dönüşüm modeli önerilmiştir. Ayrıca diğer makine öğrenmesi alanlarında sıklıkla kullanılan ince-ayar (fine-tuning) yöntemi yarı-güdümlü hiperspektral veri analizinde ilk kez kullanılmıştır. Sistemde ince-ayarla elde edilen modelden derin öznitelik vektörleri elde edilerek bu vektörler üzerinde etiketli örnek seçimi için 5 farklı kümeleme yöntemi uygulanmıştır. Bunun temel amacı farklı kümeleme yöntemlerinin sistem başarımına etkisinin araştırılmasıdır. Yarı-güdümlü öğrenme aşamasında ise transdüktif destek vektör makineleri (transductive support vector machines) ve ilk defa önerilen yarı-güdümlü seyrek gösterim sınıflayıcısı kullanılmıştır. Elde edilen sınıflama sonuçları literatürdeki en gelişkin yöntemler ile karşılaştırılmıştır.

Özet olarak bu tez çalışmasında, az sayıda etiketli örneğe sahip hiperspektral verilerin yarı-güdümlü olarak sınıflandırılması için yeni sistem çözümleri ve yeni yaklaşımlar önerilmesi amaçlanmıştır. Çalışmanın uzaktan algılama, makine öğrenmesi, görüntü işleme, yarı-güdümlü öğrenme ve derin öğrenme alanlarında çalışan araştırmacılar için faydalı bir kaynak olması hedeflenmiştir.

Anahtar Kelimeler: Hiperspektral görüntüleme, uzaktan algılama, yarı güdümlü öğrenme, sınıflama, kümeleme, derin öğrenme, ince ayar, seyrek gösterim sınıflayıcısı, öznitelik çıkarımı

Semi Supervised Learning Techniques on Hyperspectral Images

Muhammet Said AYDEMİR

Department of Computer Engineering

Doctor of Philosophy Thesis

Advisor: Assoc. Prof. Dr. Gökhan BİLGİN

Remote sensing methods are examined in two sub-headings as active and passive according to whether they send signals for detection. Hyperspectral imaging, which is one of the passive remote sensing methods, is an area that has been studied extensively by the researchers with the imaging technology developed in recent years. Hyperspectral images have spectral bands in the electromagnetic spectrum from the visible region to the infrared region. Hyperspectral imaging has a greater number of bands than multispectral imaging, which is the prior art. Multispectral images have spectral bands in range 4 to 10, while hyperspectral images have over hundred bands. Hyperspectral images are used in many applications in civilian and military fields, since each pixel in hyperspectral images allows to obtain almost continuous signal information of the region it expresses.

Due to the acquisition of hyperspectral images by airplanes and satellites, there is an atmosphere layer between the sensor and the perceived substance. Therefore, noise is generated due to atmospheric effects on hyperspectral images. These effects have more effect on some bands than other bands. Therefore, some bands are discarded by the provider in hyperspectral images. In addition to this, various noise removal methods are applied in many studies before analyzing the hyperspectral images. In this thesis, it is aimed to eliminate this noise effect by applying principle component analysis and independent component analysis.

Data labeling is a costly process in other areas, as well as in the field of hyperspectral imaging, in terms of time and labor. For this reason, in the

field of machine learning, researchers aim to carry out image analysis with a small number of labeled samples. For the purpose of this, the general name of the proposed methods is called semi-supervised learning. It is a hybrid form of learning because of its semi-supervised learning structure. The methods are between the non-guided/unsupervised clustering methods, which are not using label information and the guided/supervised classification methods, which are using the label information. Semi-supervised learning methods aim to achieve their goal with a few labeled samples by using both labeled and unlabeled data information. The main purpose of this thesis is to classify hyperspectral images as semi-supervised with a small number of labeled samples.

Semi-supervised learning methods are mainly composed of two stages. The first of these is the selection of the labeled samples and the second is the labeling of these samples. Selecting the labeled samples is as important as the labeling process. In the first part of the thesis, semi-supervised learning was applied by self-learning/self-training method which is an incremental model. Here, the labeled sample selection was performed by subtractive clustering, which is applied for the first time in the semi-supervised learning literature, and k-means clustering. The main purpose is to select the samples that will provide the most benefit/information. In the second step is based on an incremental model for labeling of unlabeled data. Following semi-supervised learning of the training set, the test set was classified by two different supervised learning techniques, such as kernel support vector machines and kernel sparse representation classifier. The results of the classifiers were combined in various ways at the decision level to obtain the system result. In addition, various feature selection and extraction methods have been applied in this section and the effects on system performance have been observed objectively.

In the other part of the thesis study, a graph-based system which is another type of semi-supervised learning methods has been proposed. In this structure, step-by-step labeling is carried out by placing the training data or all data on a graph. Spatial information was used in the graph based structure with the addition of neighboring pixels. If only the training samples were used in the graph, the test samples were labeled with different classifiers and the classification results were combined in the decision level. In this section, the deep learning-based classifier is included to the classifiers, and the classification results are added in the decision stage. In addition, the calculation of the graph-based structure was transferred to the graphics processing unit. In this way, it is possible to label all the training and test samples with the graph-based system. The results of two different solutions and the results of the state of the art studies in the literature are compared.

Artificial neural networks that emerged in the 1980s, have emerged once again as deep neural networks with the development of technology, and have enabled the achievement of achievements that could not be achieved by other machine learning methods. In the last part of the thesis, a deep learning-based system has been proposed. The proposed system basically aims to train a single deep model for hyperspectral datasets with the same characteristics, and to extract the features using this model for all data sets. In the system, a new data transformation model has been proposed in order to enable hyperspectral images to be an input to the deep learning models. In addition, fine-tuning technique, which is frequently used in other machine learning fields, was used for the first time in semi-supervised hyperspectral data analysis. Deep feature vectors were obtained from the fine-tuned model in the system and 5 different clustering methods were applied for the labeled sample selection from these vectors. The main purpose of this is to investigate the effect of different clustering methods on system performance. Semi-supervised sparse representation classifier which is proposed for the first time and transductive support vector machines were used in the semi-supervised learning phase. The classification results were compared with the state of the art studies in the literature.

In summary, this thesis study aims to propose new system solutions and new approaches for the classification of hyperspectral data with a small number of labeled samples as semi-supervised. The study aims to be a useful resource for remote sensing, machine learning, image processing, semi-supervised learning and deep learning.


Keywords: Hyperspectral imaging, remote sensing, semi supervised learning, classification, clustering, deep learning, fine tuning, sparse representation classifier, feature extraction

1.1 Literatür Özeti

Bir sahneye ait elektro-manyetik spektrumda belirli bir banttaki yansıma değerleri sahnenin gri seviye görüntüsü olarak değerlendirilebilir. Multispektral görüntüler, bir sahneye ait onlarca farklı banttaki görüntülerin bir araya getirilmesi ile elde edilmektedir. Hiperspektral görüntülerde ise yüzlerce bant bir araya getirilerek sahneye ait hiperspektral görüntüler elde edilmektedir. Gelişen hesaplama gücü ve sensör teknolojisi ile hiperspektral algılayıcıların kullanımı son yıllarda artmıştır. Bant sayısının artmasıyla elde edilen spektral bilgi yer yüzü sahneleri ve materyaller hakkında daha fazla bilgi sahibi olunmasına olanak sağlamaktadır. Bu nedenle gerek askeri gerekse sivil uygulamalar için hiperspektral görüntüleme teknolojisinin kullanımı artmıştır. Hiperspektral görüntüleme cihazları diğer bir deyişle hiperspektral sensörler yer yüzü görüntüleme amacıyla kullanıldıklarında uçak veya uydu platformlarına entegre edilmektedir. Bu nedenle hiperspektral görüntüleme genel olarak entegre edildikleri platformlardan dolayı uzaktan algılayıcılar olarak tanımlanmaktadır. Hiperspektral görüntüleme sivil amaçla gıda kalitesi tespiti, tarım alanlarının analizi, yer bilimi araştırmaları, tıbbi analizler için kullanılmaktadır. Ayrıca askeri amaçlı olarak mayın tespiti ve nesne tespiti daha özel alanlarda da kullanılmaktadır.

Uzaktan algılama yöntemleri aktif ve pasif olarak iki alt başlıkta incelenmektedir. Aktif uzaktan algılama araçları ürettikleri sinyali veya ışığı görüntülemek istedikleri sahneye veya nesneye gönderirler ve gönderdikleri sinyalin veya ışığın geri dönmesini beklerler. Pasif uzaktan algılayıcılar ise doğal yollardan aydınlanan sahneleri kontrollü olarak aydınlatmadan görüntüleyerek bilgi elde ederler. Kontrolsüz olarak aydınlanan cisimler farklı dalga boylarında farklı yansıtma ve absorbe değerlerine sahiptir. Bu yansıma ve absorbe özellikleri cisimlerin uzaktan algılama esnasında ayrıştırılmasını sağlamaktadır. Hiperspektral görüntülemede yüzlerce dalga boyunda yansıma değeri elde edilmesi sayesinde, bu ayrıştırma için, multispektral ve daha düşük bant sayısına sahip görüntüleme yöntemlerine oranla daha fazla bilgi bulunmaktadır.

Elektromanyetik spektrum bölgeleri, bölgedeki dalgalıların kullanım amacına göre isimlendirilmektedir. Elektromanyetik spektrumda $0.4 \mu\text{m}$ ile $14 \mu\text{m}$ arasında kalan bölge optik uygulamalarda kullanıldığı için optik bölge olarak isimlendirilmiştir ve 5 alt bölgeden oluşmaktadır. $0.4 \mu\text{m} - 0.7 \mu\text{m}$ arası insan gözü tarafından algılanabildiği için görünür bölge, $0.7 \mu\text{m} - 1.5 \mu\text{m}$ arası yakın kızıl ötesi (NIR), $1.5 \mu\text{m} - 3 \mu\text{m}$ arası kısa dalga boylu kızılötesi (SWIR), $3 \mu\text{m} - 5 \mu\text{m}$ arası orta dalgalı kızılötesi (MWIR), $5 \mu\text{m} - 14 \mu\text{m}$ arası ise uzun dalgalı kızılötesi (LWIR) olarak adlandırılmıştır. Elektromanyetik spektrum bölgelerinin detayları Şekil 1.1 ile incelenebilir.



Şekil 1.1 Elektromanyetik spektrum bölgesi [1]

Günlük hayatta kullanılan renkli görüntüler kırmızı, yeşil, mavi (Red, Green, Blue - RGB) olmak üzere 3 banttan oluşmaktadır. Renkli görüntülerden daha fazla bant sayısına sahip olan multispektral görüntüler ise minimum 4 banttan ve 10' lu sayılarla ifade edilen bantlardan oluşmaktadır. Multispektral görüntülerde bant aralıkları 300-400 nm arasındadır. Multispektral görüntülerden daha fazla bant sayısına sahip görüntüler ise hiperspektral görüntüler olarak ifade edilmektedir. Şu an hali hazırda aktif kullanımı olmayan fakat gelişen sensör teknolojisi ile kullanıma geçilmesi muhtemel ultraspektral görüntüler de hiperspektral görüntülerden daha fazla bant sayısına sahip olup binlerle ifade edilen bant sayısına sahiptirler. Multispektral, hiperspektral ve ultraspektral görüntülerin karakteristik özellikleri ve dahil oldukları spektrum bölgeleri Şekil 1.2 ile incelenmiştir.

Günümüzde ultraspektral görüntüleme teknolojisi aktif kullanımda olmadığı için devamlı sinyale en yakın görüntüleme teknolojisi hiperspektral görüntüleme teknolojisidir. Sık aralıklarla elektromanyetik spektrumda örneklem alınan hiperspektral görüntülerde her bir piksel ifade ettiği bölgeye ait devamlı (continuous) bir grafik çizmeye olanak sağlamaktadır. Diğer görüntüleme teknolojilerinde de olduğu gibi hiperspektral görüntülerde de bir piksel bir veya birden fazla cismin birleşimini ifade edebilmektedir. Hiperspektral görüntünün uzamsal çözünürlüğü yüksekse her bir piksele karşılık bir cismin düşme olasılığı yüksektir. Eğer bir hücre




Şekil 1.2 Uzaktan algılama teknolojileri spektrum karakteristikleri [1]

tek bir cisimden oluşuyorsa devamlıya yakın olarak çizilen grafik cismin/maddenin karakteristik özelliğini yansıtır. Bu grafiğe hiperspektral görüntüleme literatüründe spektral imza adı verilmektedir. Doğada bulunan her bir cismin kendisine ait bir spektral imzası bulunmaktadır. Eğer bir piksel birden fazla cismi ifade ediyorsa bu piksele ait spektral imza pikseli oluşturan cisimlerin imzalarının birleşimi şeklinde ortaya çıkar.

Uzaktan algılama teknolojilerinde görüntüler, algılayıcı tarafından oluşturulduktan sonra bazı ön işlemlerden geçirilmek zorundadır. Bu işlemlerden ilki atmosferik düzeltmedir. Bu ön işlemin uzaktan algılanan hiperspektral görüntülerde de uygulanması zorunluluktur. Bunun nedeni ise doğal olarak aydınlanan cisim üzerinden algılayıcıya gelen yansımalar, algılayıcıya gelene kadar atmosfer tabakası üzerinden geçmektedir. Atmosferde bulunan gazlar bu yansımalar üzerinde farklı spektrumlarda farklı değişimlere sebep olmaktadır. Gazların neden olduğu bu atmosferik etkiler Şekil 1.3 ile görülmektedir. Atmosferik etkilerin düzeltilmesiyle daha stabil analizler gerçekleştirilebilir. Düzeltme işleminin gerçekleştirilmemesi halinde spektral imza değişeceğinden dolayı, düzeltme yapmaksızın yürütülen hiperspektral görüntü analizleri güvenilir olmayacaktır. Hiperspektral görüntülerde gürültü giderme/azaltma yöntemleri hala aktif bir araştırma alanıdır. Bunun nedeni veride varolan gürültünün sonrasında yapılacak tüm analiz, sınıflama, kümeleme vb. gibi işlemlerin başarımını doğrudan etkilemesidir. Bu nedenle gürültü giderimi üzerine literatürde oldukça fazla sayıda çalışma bulunmaktadır.

Veri kümeleme, bazı benzerlik ölçütlerine (örneğin Öklid mesafesi) dayalı çok boyutlu verilerde doğal grupları veya kümeleri belirleme işlemidir [2, 3]. Kümeleme sınıf bilgisi kullanmadığından dolayı kullanım alanı çok geniştir ve bu nedenle makine



Şekil 1.3 Farklı spektrumlarda atmosferik etki

öğrenmesi ve örüntü tanıma alanlarında sıkça kullanılan önemli bir süreçtir [4]. Ayrıca, kümeleme işlemi yapay zekanın temelini oluşturan işlemler arasında yer alır [5]. Kümeleme algoritmaları; görüntü segmentasyonu [6–8], vektör ve renkli görüntü nicemlemesi [9–11], veri madenciliği [12], sıkıştırma [13] ve makine öğrenmesi [14] gibi birçok uygulamada kullanılmaktadır. Bir küme genellikle bir küme merkezi (veya ağırlık merkezi) ile ifade edilir [15]. Veri kümeleme işlemi, etiketsiz örüntü tanıma işleminde zor bir sorundur, çünkü veri kümeleri farklı şekil ve boyutlara sahip olabilirler [3]. Bu çalışmada etiketli örnek seçimi için farklı kümeleme yöntemleri kullanılmıştır. Literatürde sıklıkla kullanılan kümeleme yöntemlerinde bazıları temel karşılaştırma yöntemi olarak kullanılmıştır. Bazıları ise farklı alanlarda önerilmiş ve kullanılmış olmasına rağmen bu alanda ilk defa kullanılan yöntemlerdir. Bu kümeleme yöntemleri K-ortalamlar (k-means), eksiltici (subtractive), ortalama-kaydırma (mean-shift), K-medoids ve db-scan kümeleme algoritmalarıdır.

K-ortalamlar kümeleme algoritması en bilinen ve en çok kullanılan kümeleme yöntemlerinden biridir. Hiyerarşik kümeleme yönteminden daha basit ve hesaplama maliyeti daha az olduğu için daha hızlıdır. Bunun yanında çok büyük sayıdaki değişkenler için kullanılabilir. Ancak farklı küme sayıları için farklı kümeleme sonuçları üretir, bu nedenle uygun küme sayısı ile ilklendirilmesi gerekir. K-ortalamlar kümeleme [16–19] çalışmalarında farklı bilim dallarında birbirinden bağımsız olarak keşfedildiği için zengin ve çeşitli bir tarihe sahiptir. K-ortalamlar kümeleneenin ilk önerildiği tarihten 50 yıldan uzun zaman geçmesine rağmen hala en çok kullanılan kümeleme yöntemlerinden biridir.

Yager ve Filev, küme ağırlık merkezlerini tahmin etmek için dağ yöntemini

geliştirmiştir [20]. Bu basit yöntem, dağ fonksiyonunu bir ızgara uzayda inşa eder ve küme merkezlerini yok ederek tahmin eder. Bununla birlikte, dağ yöntemi düşük boyutlu veri kümeleri için etkili olsa da, yüksek boyutlu verilere uygulandığında yetersiz kalmaktadır. Bu yöntemin hesaplama karmaşıklığını azaltmak için Chiu, dağ işlevini, eksiltme yöntemi olarak bilinen bir yaklaşım olan ızgara noktaları yerine veri noktalarından hesaplamayı önermiştir [21]. Eksiltici kümeleme veri noktalarındaki en optimal küme merkezini yoğunluk tabanlı olarak bulan bir yöntemdir. Velthuizen, büyük veri kümelerinin etkili bir şekilde kümelenmesini sağlamak için dağ ve çıkarma yöntemlerinin uygulanmasını geliştirmiştir [22] ve Pal, dairesel kabuk şeklindeki kümeleri tespit etmek için bu algoritmaları genişletmiştir [23]. Yao ise, dağ fonksiyonu yerine bir entropi fonksiyonu kullanmıştır; bu yaklaşımda, aday küme ağırlık merkezi olarak minimum entropiye sahip bir veri noktası seçilmektedir [24].

Ortalama-kaydırma (mean-shift) kümeleme, yerel maksimum yoğunluk tahminini bulmak için Parzen pencere tekniğini kullanan ve parametrik olmayan bir çekirdek yoğunluğu kestirimi yöntemidir. Klasik K-ortalamlar kümeleme yaklaşımının aksine, veri dağılımı ve küme sayısı hakkında önceden belirlenen bir varsayım yoktur [25]. Ortalama kayma, ilk kez Fukunaga ve Hostetler tarafından önerilmiştir [26], daha sonra Cheng tarafından görüntü analizi için kullanılmıştır [27]. Daha yakın zamanda da Comaniciu, Meer ve Ramesh tarafından segmentasyon [28], adaptif yumuşatma [28] ve nesne takibi [29] gibi düşük seviyeli görüntü işleme problemlerinde kullanılmıştır.

K-ortalamlar kümeleme yöntemi hesaplama maliyeti açısından oldukça verimli olmasına rağmen, aykırı değerlere karşı duyarlı olduğu bilinmektedir. Bu nedenle k-medoid kümeleme bazı durumlarda, medoid denilen temsili nesnelerin centroid yerine düşünüldüğü durumlarda kullanılır. Yöntem, bir kümedeki en merkezi konumdaki nesneye dayandığından, k-ortalamlar kümeleme ile karşılaştırıldığında aykırı değerlere karşı daha az hassastır. K-medoid kümeleme için pek çok algoritma arasında, Kaufman ve Rousseeuw tarafından önerilen medoidlerin etrafına bölünmenin (partitioning around medoids - PAM) en güçlü olduğu bilinmektedir [30]. Bunun yanında PAM hesaplama karmaşıklığından dolayı büyük veri kümelerinde verimsiz çalışmaktadır [31]. Bu nedenle, k-medoid kümeleme için yeni algoritmalar geliştirmek için farklı çalışmalar gerçekleştirilmiştir. Kaufman ve Rousseeuw, PAM' ı tüm nesneler yerine örneklenmiş nesneler üstünde uygulayan CLARA yöntemini önermişlerdir [30]. Lucasius ve arkadaşları tarafından yapılan çalışmada CLARA'nın performansının artan küme sayısı ile birlikte hızla düştüğü raporlanmıştır [32]. Yapılan çalışmada, performansı CLARA' dan daha iyi rapor edilen ancak küme sayısı arttıkça hesaplama yükü artan, genetik algoritma tabanlı yeni bir K-medoid kümeleme yaklaşımı önerilmiştir. [33] çalışmasında, büyük veri kümeleri için CLARA ve diğer

bazı deęişkenlerin performansını karşılaştırılmıştır. Ayrıca [34] çalışması, bazı komşu nesnelerden yeni medoidleri güncelleyen etkili bir PAM tabanlı algoritma önermiştir.

DBSCAN (Density-Based Spatial Clustering of Applications with Noise), Ester ve arkadaşları [35] tarafından önerilen parametrik olmayan yoğunluk tabanlı bir kümeleme tekniğidir. Bölümleme yöntemleri ve hiyerarşik kümeleme kategorilerinin altına da girmeyen dbscan, veri uzayında bir kümenin yüksek yoğunluklu bir bölge olduğunu kabul eder. Yoğunluğa dayalı olmayan kümeleme yöntemleriyle karşılaştırıldığında, farklı şekil ve boyutlardaki nesneleri/sınıfları/desenleri/yapıları tespit ederken kullanışlı olan benzersiz ve gelişmiş özelliklere sahiptir. Dbscan, bir veri setinde bulunan gruplar hakkında ön bilgi olmadan karşılaştırılabilir bir yoğunluğa sahip olduklarında, “doğal” kümeleri ve bunların veri alanı içindeki düzenlerini bulmaya yarayan iyi bir adaydır [36]. Yöntem ilk olarak uzamsal verilerin kümelenmesi için önerilmiştir. Özellikleri sayesinde algoritma kısa sürede popüler olmuştur ve diğer veri türleri için de bir kümeleme yaklaşımı olarak uygulanmıştır. Uygulamalarının bazı örnekleri arasında inşaat mühendisliği (mekansal sivil altyapı ağlarını gruplamak [37]), kimya [38], spektroskopi (tek parçacık kütle spektrumlarının gruplandırılması [39] ve uçuş kütle spektrometrisinin aerosol zamanı [40]), biyoloji (böceklerin kimyasal feromon verilerine göre kümelenmesi [41, 42]) ve tıbbi görüntülere dayalı tıbbi teşhis (beyin atrofi örüntülerinin tespiti [43] ve cilt lezyonlarının saptanması [44, 45]) bulunmaktadır. Ayrıca üç boyutlu görüntülerin (hiperspektral görüntüler) bölütlenmesi için uzaktan algılama alanında da kullanılmıştır [46].

1998’ de Vapnik tarafından önerilen destek vektör makinesi (support vector machine - SVM), küçük örneklerle örüntü tanıma için etkili bir yöntemdir [47]. Literatürde SVM’ in temelini 1980’ li yıllarda yine Vapnik tarafından yapılan [48] çalışmasına dayandığı bilinmektedir. Destek vektör makineleri başlangıçta ikili sınıflandırma için tasarlanmıştır [49]. Şu anda çok sınıflı SVM için iki tür yaklaşım vardır. Biri birkaç ikili sınıflandırıcı oluşturmak ve bu sınıflandırıcıları birleştirmek, diğeri ise tüm verileri doğrudan bir optimizasyon formülasyonunda düşündürmektir. Çok sınıflı sınıflandırma için SVM kullanımı için literatürde bir çok çalışma gerçekleştirilmiştir [50]. SVM’ ler henüz çıktığı ilk yıllarda örüntü tanıma alanında; izole el yazısı tanıma [49, 51], nesne tanıma [52], konuşmacı tanıma [53], yüz tespiti [54] ve metin sınıflama [55] gibi bir çok alanda kullanılmıştır. Sonraki yıllarda da neredeyse tüm makine öğrenmesi alanlarında araştırmacılar sıklıkla SVM’ e başvurmuştur.

Transdüktif destek vektör makinesi (Transductive support vector machine - TSVM), SVM’nin yarı güdümlü bir versiyonudur. Eğitim aşamasında, yavaş yavaş (yinelemeli işlem), hem etiketli hem de etiketlenmemiş örnekleri dikkate alarak çekirdek uzayında

güvenilir bir ayırma hiper düzlemi arar. Etiketlenmemiş veriler SVM için marj ile ilgili ek bir bilgi kaynağı olarak kullanılabilir. Transdüktif öğrenmede amaç, etiketlenmemiş verilerin bir etiketini bulmaktır, böylece doğrusal bir sınır ile hem orijinal etiketli verilerde hem de (etiketli varsayılan) etiketlenmemiş verilerde maksimum marjı aramaktır. Bu sayede, özellikle zayıf eğitim kümelerinde veya mevcut eğitim örnekleri yetersiz olduğunda SVM'lerin genelleme performansını iyileştirebilir [56].

Literatürde örüntü sınıflandırma için TSVM' e dayanan çok sayıda yarı-güdümlü yöntem bulunmaktadır [56–61]. Tüm bu yöntemler, çekirdek uzayının düşük yoğunluklu bölgesinden geçen bir karar hiper düzlemi bulmaya çalışmaktadır. [62] çalışması yarı-güdümlü yaklaşımların iyi bir incelemesidir. [56]' de, metin sınıflandırması için ikinci dereceden optimizasyon problemi çözülerek TSVM uygulanmıştır. Bu yöntem, etiketlenmemiş pozitif ve negatif örnekler arasındaki oran transdüktif öğrenmenin başlangıcında bilindiğinde etkilidir. Chapelle ve Zien [57] ise, çekirdek uzayının düşük yoğunluklu bölgelerinde karar sınırını bulmak için gradyan iniş (gradient descent) tekniğini kullanarak transdüktif SVM' in amaç fonksiyonunu optimize eden bir yöntem önermişlerdir. Sindhwani ve Keerthi tarafından önerilen [58] çalışmasında, büyük ölçekli metin uygulamalarına uygun olan doğrusal TSVM için hızlı bir yöntem sunulmuştur. [59]' de, TSVM'nin standart objektif fonksiyonuna ek bir kriter dahil edilmiştir ve daha sonra bu objektif fonksiyonun optimize edilmesi için genetik bir algoritma kullanılmıştır. [60] çalışmasında, SVM' in karar marjı içinde bulunan örneklerden minimum mesafeye sahip olan mevcut etiketlenmemiş örneklerden sırasıyla pozitif ve negatif örnekleri tekrarlayarak transdüktif örnekler olarak seçen ilerlemeli (progressive) bir TSVM algoritması önerilmiştir. Yöntemde aynı zamanda seçilen transdüktif örneklerin yanlış etiketlemesini azaltmak için dinamik ayarlama kullanılmıştır. Bruzzone ve arkadaşları ise yaptıkları [61] çalışmasında, [60]' da sunulan algoritmayı, transdüktif öğrenme sürecinin her bir yinelemesinde mevcut etiketlenmemiş örneklerden pozitif ve negatif örnek seçiminin toplu/yığın (batch) şeklinde yapılması şeklinde değiştirerek önermişlerdir.

Yarı-güdümlü öğrenme (YGÖ), makine öğrenmesinin güdümlü/eğitici ve güdümsüz/eğitici öğrenme alanlarıyla karşılaştırıldığında daha yeni bir çalışma alanı olduğu görülmektedir. Özellikle makine öğrenmesi alanında veri miktarının artması, veri etiketlemenin maliyeti ve iş gücü ihtiyacı gibi zorluklardan dolayı yarı-güdümlü öğrenme ön plana çıkmıştır. YGÖ' deki temel amaç, sınırlı sayıdaki eğitim verisinin çoğaltılarak, oluşturulacak modelin gürbüzlüğünün daha az veri miktarıyla sağlanabilmesidir.

Son yıllarda hiperspektral görüntüleme literatüründe güncel YGÖ teknikleri birçok çalışmada yer almıştır. YGÖ tekniği temel olarak hiperspektral görüntüleme alanında

kümeleme, özellik çıkarımı (bant seçimi) ve sınıflama için kullanılmaktadır. Örneğin [63–66] çalışmalarında temel olarak YGÖ ile sınıflama amaçlanırken, [67–70] çalışmalarında ise bant indirgeme başarımının arttırılması için YGÖ kullanılmıştır.

Hiperspektral görüntüleme alanında yapılan YGÖ uygulamalarından sınıflamayı amaçlayan [71] çalışması, yeni etiketli veri eklemek için Aviris verisi üzerinde Sparse Multinomial Logistic Regression (SMLR) ve Logistic Regression via Variable Splitting and Augmented Lagrangian (LORSAL) algoritmaları ile en faydalı yani en çok bilgi sağlayan örneğin eklenmesini amaçlamıştır. [72] çalışmasında ise Soft-sparse multinomial logistic regression (S^2MLR) yöntemi hem etiketli hem de sonradan etiketlenen veriler üzerinde uygulanmıştır. Etiketleme için subspace-based MLR (MLRsub) uygulanmıştır. Aviris üzerinde deneyler yapılan bu çalışmada, Expectation Maximization (EM) tabanlı olarak yeni etiketler tek bir sınıfa değil de fuzzy olarak ayrıştırma (unmixing) mantığıyla atanmıştır. [73] çalışmasında Aviris üzerinde öncelikle bant seçimi uygulanmıştır. Daha sonra kümeleme yapılmıştır fakat kümeleme yapılırken bilgi olarak piksel uzaklıkları da eklenmiştir. Daha sonra uzman tarafından bazı küme elemanlarına etiketleme yapılmıştır ve k-en yakın komşuluk (k-NN) ile sınıflama işlemi gerçekleştirilmiştir. Rosis Pavia Üniversitesi veri kümesi üzerinde yapılan [65] çalışmasında DVM ve k-NN sınıflandırıcıları karşılaştırma için kullanılmıştır. Diğer çalışmalardan ayrıldığı en büyük noktanın ölçeklenebilir olmasından bahsedilmiştir. Burada kastedilen, diğer çalışmalarda hiperspektral verinin hepsinin kullanılmadığı bu çalışmada etiketsiz verinin istenen kısmının kullanılabileceğidir. Hem küçük bir eğitim kümesi hem de orijinal eğitim verisi üzerinde karşılaştırma yapılmıştır. K-medoid kümeleme yöntemi ve graf-tabanlı YGÖ uygulanmıştır. Yeni bir aktif öğrenme yaklaşımının önerildiği [74] çalışmasında Rosis Pavia Üniversitesi verisi üzerinde en çok bilgi getiren örneklerin seçimini amaçlayarak YGÖ gerçekleştirilmiştir. Bu işlem sınıflama başarısını en çok artıran örnekleri seçerek yapılmaktadır. Random sampling (rastgele örnekleme) ile karşılaştırma yapılmıştır. Veri kümesi olarak Pavia Center verisini kullanan [75] çalışmasında bilinen açma kapama işlemlerinin gelişmiş versiyonu olan morfolojik profillerle boyut indirgemesi hedeflenmiştir. Özellik çıkarımı için öncelikle hiperspektral görüntüler için bu profillerin oluşturulması gerektiğinden bahsedilmiştir. Daha sonra da bu oluşturulan morfolojik profillerle boyut indirgemesi için yarı-güdümlü bir özellik çıkarım metodu ortaya koyulmuştur. Nasa EO-1 uydusu tarafından 2001 yılında alınan Okavango (Delta,Botswana) verisi üzerinde yapılan [76] çalışmasında, global maksimumu hedefleyen DVM sınıflayıcısına iteratif bir faz eklentisi yapılarak yeni bir yöntem sunulmuştur ve bunun sonucunda global minimum hataya ulaşılmaktadır. Daisex-99 verisiyle yapılan [77] çalışmasında EM tabanlı hem etiketli hem de etiketsiz veriyi kullanan bir yöntem önerilmiştir. C-means ile kümeleme yapılırken,

son-işlem olarak yumuşatma işlemi uygulanmaktadır. Aviris veri kümesi üzerinde yapılan [78] çalışmasında lineer spektral ayrıştırma (unmixing) ile MLR bir araya getirilerek en son teknoloji bir sınıflayıcı amaçlanmıştır. Bunun yanında hem uzamsal hem de spektral bilgiyi kullanan yeni bir aktif örnekleme yaklaşımı ortaya koyulmuştur. Washington DC Mall veri kümesi ile yapılan [79] çalışmasında parçacık sürü optimizasyonu (Particle Swarm Optimization - PSO) ve DVM birleştirilerek sınırlı eğitim verisi problemine çözüm bulunmaya çalışılmıştır. PSO ile etiketsiz örnekler etiketlenerek DVM' in sınıflama başarımının artırılması hedeflenmiştir. [80] çalışmasında IEEE-GRS/Telops veri kümesi kullanılarak eğitici ve eğitici olmayan SOM (Self Organizing Maps) yöntemleri kullanılmıştır. SOM kullanımına farklı yaklaşımlar getirilmiştir. Multi-spektral Flighlines C1 ve Hiperspektral Aviris verisi üzerinde testlerin yapıldığı [81] çalışmasında etiketsiz veri kullanılarak yapılan kümelemenin ardından, kümeleme sonuçları kullanılarak çekirdek tahmininde bulunulmuştur. Etiketsiz veri kümelerinin torba (bag) olarak düşünüldüğü çalışmada, one-against-one çekirdek DVM ile torbalı (bagged) DVM uygulanmaktadır. Üç temel avantajı olduğundan bahsedilen [82] çalışması, Aviris Indian Pine verisi üzerinde test edilmiştir. Çekirdek (kernel) bir metot kullandıkları için boyutluluk sorunundan (curse of dimensionality), yarı-güdümlü bir yöntem olduğu için etiketsiz verinin katkısının elde edildiğinden ve kompozit çekirdekler (composite kernels) kullandığı için bağlamsal bilgi kullanıldığından bahsedilmiştir. Etiketli ve etiketsiz verinin bulunduğu çok büyük bir çekirdek matrisine dayanmasından dolayı Nyström metoduyla hızlandırma amaçlanmıştır. Graf-tabanlı YGÖ ile kötü konumlanmış sınıflama (ill-posed classification) problemine (yüksek boyutlu uzay ve az etiketli örnek sayısı) çözüm hedeflenmiştir.

Etiketli veri bilgisini sınıflama yerine kümeleme için kullanan [83] çalışmasında yöntem 2 aşamadan oluşmaktadır. İlk aşamada YGÖ ile sınıf dağılımlarından bilgi çıkarımı, ikinci kısımda da kümeleme yapılmıştır. Aviris veri kümesinde yapılan çalışma, hem etiketli hem de etiketsiz veriler ile graf tabanlı modelleme yapılmıştır. Aviris Indian Pine verisi üzerinde yapılan [84] çalışmasında öncelikle hiyerarşik eğitici olmayan sınıflama yani kümeleme yapılmaktadır. Daha sonra az sayıda eğitim örneği ile her küme bir sınıfa atanarak küme seviyesinde sınıflama yapılmıştır. Etiketli verilerle elde edilen sınıflama sonucunda her piksel için bir güvenilirlik skoru elde edilmektedir. Aktif öğrenmeyle sınıf üyelik güvenilirlik skorunu en fazla artıracak yani en çok bilgi sağlayacak örnekler etiketlenerek YGÖ gerçekleştirilmektedir. Bu çalışmalarda etiketli verinin temel kullanım amacı sınıflara göre verinin dağılım bilgisinin kullanılarak kümeleme başarımının artırılmasıdır.

Bant seçimi için YGÖ kullanan [67] çalışması seyrek lineer regresyon modeli kullanarak bant sayısını azaltmayı hedeflemektedir. Etiketsiz veriyi etiketlemek

için hiper-graf önerilmiştir. Sonrasında hem etiketli hem de etiketsiz veriyi kullanarak regresyon katsayıları hesaplanmıştır. Her bandın katkı skoru hesaplanarak skoru büyük olan bantlar seçilmiştir. Çalışmadaki deneyler APhi veri kümesi üzerinde yapılmıştır. [69] çalışmasında, Aviris Indian Pine veri kümesi üzerinde Semi-Supervised Probabilistic Principal Component Analysis (S^2PPCA) ve Semi-Supervised Local Fisher Discriminant Analysis (S^2LFDA) ve Semi-Supervised Dimensionality Reduction with pairwise constraints (S^2DRpc) yöntemleri öznitelik azaltımı için kullanılmıştır. Bu öznitelik azaltım yöntemlerinin PCA' den daha iyi sonuçlar verdiği gösterilmiş. Aviris verisi üzerinde deneylerin yapıldığı [85] çalışmasında öznitelik çıkarımı için yeni bir metot olarak Semi-Supervised Local Embedding (SSLE) yöntemi önerilmiştir. Yöntem eğitici bir yöntem olan Linear Discriminant Analysis (LDA) ile eğitici olmayan bir yöntem olan Local Linear Embedding (LLE) yöntemlerinin birleşiminden oluşmaktadır. Temel bileşenlerin kullanılması fikrinden ortaya çıkan yöntemde DVM ile sınıflandırma yapılmıştır. Diğer bir bant seçim çalışması olan [86] Rosis Pavia Center verisi üzerinde test edilmiştir. GMM (Gaussian Mixture Models) ile bant seçimi yapılmıştır fakat çalışmadaki kritik nokta bütün sınıflar için aynı bantların kullanılmamasıdır. Bunun yerine sınıf çiftleri için seçilen bantlar kullanılarak one-against-one DVM ile sınıflama gerçekleştirilmektedir. Pavia Center ve Aviris Indian Pine veri kümeleri üzerinde yapılan [87] çalışması üç aşamadan oluşmaktadır. Seyrek bir sınıflayıcı ile en az hatayı veren bantlar seçildikten sonra uzamsal yumuşaklık göz önüne alınarak, uzamsal komşuluk benzerliğinden kaçınma sağlanmaktadır. Son olarak amaç fonksiyonu alternatif bir iterasyon yöntemiyle optimize edilmektedir. [88] çalışmasında PCA ve Fisher Discriminant Analysis (FDA) ile karşılaştırma yapılmıştır. Önerilen yöntemde ikili kısıtlarla yüksek boyuttan düşük boyuta izdüşüm hedeflenmiştir. Bu işlem gerçekleştirilirken hem etiketli hem de etiketsiz veri kullanılmıştır. [89] çalışmasında Semi Supervised Manifold Local Fisher Discriminant Analysis (S^2MLFDA) kullanılarak etiketsiz veriden etiketli gibi yararlanılması amaçlanmıştır. Yöntem yerel dağılım matrisini ve manifold yapısını etiketli ve etiketsiz veriden bilgi çıkarımı için kullanmaktadır. Bunun yanında sınıflama başarısını artırmak için üssel formda bir ağırlıklandırma katsayı yöntemi önerilmiştir. Deneyler Aviris Indian Pine veri kümesi üzerinde yapılmıştır; k-NN sınıflayıcısı kullanılarak PCA, FDA, LFDA, SELF, LGSSDR yöntemleriyle karşılaştırılmıştır. Aviris Cuprite Nevada verisi üzerinde uygulanan [90] çalışmasında seyrek gösterim yöntemi kullanılarak GPU ile spektral ayırıştırma (unmixing) yapılmıştır. Seyrek gösterime yarı-güdümlü bir yaklaşım adapte edilerek veride bulunan materyallerin çeşitliliğinin artırılması amaçlanmıştır. Materyallerin bulunma oranlarını tespit eden bu yöntem, Spectral Unmixing by Splitting and Augmented Lagrangian (SUNSAL) yöntemini temel almıştır. GPU' nun hesaplama gücünden faydalanılmış çalışmanın, en optimize seri uygulamadan

164 kat daha hızlı olduđu raporlanmıřtır. Hyperion (Xuzhou,Çin) verisi üzerinde yapılan [91] çalışması, basit ve verimli bir metrik öğrenme algoritması olan Relevant Component Analysis (RCA) ile, öznitelik metriklerinden oluşturulan beyazlatma dönüşüm matrisiyle bant seçimi yapmaktadır. Bu metrik tek bir banttaki ayırıcılığa bakarken aynı zamanda herhangi iki bant arasındaki spektral korelasyonu da göz önünde bulundurmaktadır. Daha sonra bir kümeleme yöntemi ile en iyi alt kümeyi bulmayı amaçlamaktadır.

Hiperspektral görüntü sınıflamasında DVM' ler en yoğun kullanılan sınıflayıcılardan biridir [92]. Bunun temel nedeni çekirdek (kernel) tabanlı eğitim mantığıyla yüksek başarımların elde edildiğı bir sınıflayıcı olmasıdır [93]. Seyrek gösterim sınıflayıcısı (SGS) ise örüntü tanımada ses, görüntü, yüz ve hareket tanıma gibi farklı alanlarında sınıflama için kullanılmasına rağmen hiperspektral görüntüleme [90] çalışmasındaki gibi daha çok hiperspektral görüntü ayrıştırma için kullanılmaktadır. Literatürde SGS, sınıflama için kullanıldığı durumlarda genellikle çekirdek tabanlı olarak kullanılmıştır [94].

Seyrek gösterim sınıflayıcısı sıkıştırma ve gürültü giderimi gibi bir çok sinyal işleme alanında kullanılmaktadır [95]. Daha önceki yıllarda daha çok sinyal işleme alanında kullanılan seyrek gösterim sınıflayıcısı son yıllarda yaygın olarak bilgisayarla görme ve örüntü tanıma alanlarında kullanılmaktadır. Görüntü işleme ve örüntü tanıma alanlarında yüz tanıma [96–98], görüntü düzeltme [99], süper çözünürlük [100], nesne tespiti [101], nesne takibi [102] ve görüntü gürültü giderimi [103] gibi bir çok alt alanda çalışılmıştır. Görüntü işlemenin bir çok alanında kullanılmasıyla beraber hiperspektral görüntü işleme alanında da; ayrıştırma (unmixing) [104, 105], bant seçimi [106, 107], hedef tespiti [108], gürültü giderimi [109], görüntü düzeltimi [110], süper çözünürlük [111], boyut indirgeme [68, 69, 112] ve sınıflama [66, 113–118] gibi alanlarda kullanılmaktadır.

Kullanımı son yıllarda oldukça artan bir makine öğrenimi yaklaşımı olan “Derin Öğrenme (Deep Learning - DL)” konusunun temelleri 90'lı yıllara dayanmaktadır. Bu konuda, ilk temel çalışma, bu alandaki öncü isimlerden biri olan Yann LeCun tarafından yapılan ve Evriřimsel Sinir Ağları'nın kullanıldığı el yazısı tanıma sistemidir [119]. El yazısı tanıma problemi, 2006 yılında, alandaki bir başka öncü isim Geoffrey Hinton tarafından yeniden ele alınmış ve başarılı bir “Deep Belief Network” modeli ortaya koyulmuştur [120]. DL temel olarak yapay sinir ağlarının (Artificial Neural Networks - ANN) gelişmiş bir türüdür ve geleneksel makine öğrenme yaklaşımlarından tamamen farklıdır. Geleneksel makine öğrenmesi yaklaşımlarında belirlenen bir öznitelik üzerinden sınıflama veya kümeleme gibi hedef işlem gerçekleştirilmektedir. Fakat derin öğrenmede her katmanda farklı öznitelikler derin ağ tarafından otomatik

olarak öğrenilmektedir. Bu nedenle hangi öz niteliğin kullanılacağına tasarlayıcı karar vermemektedir, derin ağ veri üzerinden ayrıştırıcı öz nitelikleri öğrenmektedir. DL yüksek başarımı sayesinde bir çok araştırmacının dikkatini çekmiştir. Diğer bir çok alanda olduğu gibi hiperspektral veri analizinde de bir çok araştırmacı farklı amaçlarla derin öğrenme üzerine çalışmaktadır. Hiperspektral görüntülemelerde sınıflama [121–123], kümeleme [124], boyut indirgeme [125] ve öz nitelik çıkarımı [125–129] gibi alanlarda araştırmacı DL ile ilgili çalışmalar gerçekleştirmişlerdir.

Güçlü grafik işlemci birimlerinin (Graphics Processing Unit - GPU) günlük hayata girmesiyle birlikte artan hesaplama güçleri ve önemli problemlerle ilgili makine öğrenmesi yaklaşımlarının ihtiyaç duyduğu verikümelerindeki artışla birlikte kullanımı oldukça yaygınlaşan “Derin Öğrenme” konusundaki kırılma noktalarından birisi 2012 yılında düzenlenen ImageNet nesne tanıma yarışmasını [130] kazanan AlexNet isimindeki Evrişimsel Sinir Ağı modeli [130] olmuştur. Bu derin sinir ağı, büyük çaplı verikümelerinin güçlü hesaplama gücüne sahip sistemlerde işlendiği ve ciddi başarı elde edilen ilk çalışmalardan biri olarak literatürdeki yerini almıştır. Bahsedilen modellerle alınan başarılı sonuçlar nesne tanıma ve diğer alanlarda Evrişimsel Sinir Ağı (Convolutional Neural Network - CNN) modelleri aktif bir şekilde kullanılmaya başlanmıştır.

Shaoqing Ren ve arkadaşları [131] PASCAL VOC 2007, 2012, ve MS COCO veri kümelerinde dönemin en iyi nesne tespit doğruluğunu yakalayan ve GPU üzerinde saniyede 5 sahne işleyebilen bir sistem geliştirdiler. 2015 yılında düzenlenen ILSVRC and COCO yarışmalarının pek çok kategorisinde birinci olan sistemler bu çalışmada anlatılan daha hızlı R-CNN (faster Recurrent Convolutional Neural Network - RCNN) ve RPN (Region Proposal Network) derin yapılarını temel almışlardır.

Derin öğrenme ile elde edilen nesne tespit ve tanımadaki başarılı sonuçlardan yola çıkarak Ryan Kiros ve arkadaşları [132] nesne tespiti yapmadan Flickr8K ve Flickr30K verikümeleri üzerinde o zamana kadarki en iyi tanıma sonuçlarına ulaşmışlardır. Junhua Mao ve arkadaşları derin ağlar kullanarak otomatik resim etiketleme üzerine bir sistem tasarlanmıştır [133]. Jeff Donahue ve arkadaşları derin ağlar kullanarak otomatik video etiketleme sistemi geliştirdiler [134]. Aishwarya Agrawal ve arkadaşları ise resimler hakkında sorulan sorulara cevap veren akıllı bir sistem ortaya koymuşlardır [135].

[131] çalışmasında olduğu gibi Sermanet ve arkadaşları CNN yapısını nesneleri tespit etmek ve sınıflandırmak için kullandılar [136]. Nesne tespitinin özelleşmiş bir hali olan insan tespiti için Russell Stewart ve Mykhaylo Andriluka derin modelleri kalabalık sahnelerdeki insanları tespit etmek için kullandılar [137].

Joseph Redmon ve arkadaşları Fast YOLO adında, insan tespit başarısı daha düşük olan fakat saniyede 155 frame işleyebilen bir sistem geliştirdiler [138]. İnsan tespitindeki sonuçlardan hareketle CNN insan tabanlı video analiz problemlerinde de uygulanmaya başlanmıştır [139]. Guosheng Lin ve arkadaşları derin modeller kullanarak anlamlı video parçalaması yapan bir sistem geliştirmişlerdir [140].

Nesne tanımda alınan başarılı sonuçlar yüz ile ilgili tanıma, cinsiyet ve yaş tahmini gibi biometrik problemlerin çözümü için de ilham kaynağı olmuş, bu yönde “Derin Öğrenme” tabanlı yaklaşımlar sunulmuştur [141–143]. Nian Liu ve arkadaşları yüz tespitini ve tanımasını daha iyi hali getirmek amacıyla derin öğrenme tabanlı insan yüzleri üzerinde göz sabitlemesi yapmıştır. Bu sistem 4 veri kümesinde (MIT, Toronto, Cerf, NUSEF) o zamana kadarki yayınlanmış en başarılı sonuçları elde etmiştir.

Son yıllarda DVM’lerin yerini diğer alanlarda olduğu gibi hiperspektral görüntülemeye de derin sinir ağları (deep neural networks) daha özel ismiyle evrimsel sinir ağları (convolutional neural networks) yerini almıştır [144] [123]. DL çok katmanlı yapısı sayesinde verinin doğrusal olarak ayrılmasını sağlayan bir uzaya iz düşümünü bulmayı amaçlamaktadır [130].

Uzaktan algılama alanında yapılan [145] çalışmada DL ile sınıflandırma problemi ele alınarak diğer istatistiksel sınıflama metotlarından daha başarılı olduğu raporlanmıştır. Bir diğer uzaktan algılama problemi olan kümeleme konusunda DL yaklaşımının başarımı Essam ve arkadaşları tarafından yapılan [146] çalışmada diğer yöntemlerle karşılaştırmalı olarak sunulmuştur.

Bu çalışmada hem önemli bir uzaktan algılama teknolojisi olan hiperspektral görüntüleme hem de güncel bir makine öğrenmesi tekniği olan YGÖ bir araya getirilerek yarı-güdümlü bir hiperspektral sınıflama sistemi oluşturulması amaçlanmıştır. Bu sayede etiketleme maliyeti yüksek olan hiperspektral görüntülerde daha az etiketli veriyle sınıflama yapılabilmesi amaçlanmıştır. Bunun dışında yapay sinir ağlarının hesaplamaya teknolojisinin gelişmesiyle yeni bir çeşidi olan derin öğrenme, görüntü işlemeye özelleşmiş haliyle evrimsel sinir ağları sistem içine entegre edilmiştir. DVM, evrimsel sinir ağları ve derin sınıflayıcı ile birleştirilmiş bir sınıflayıcı ortaya koyulmuştur. Bu kapsamda sınıflayıcıların tahmin olasılıkları değerlendirilerek emin olunmayan kararlarda diğer sınıflayıcıların tahminleri de değerlendirilerek karar seviyesinde bir birleştirme gerçekleştirilmiştir.

1.2 Kullanılmakta Olan Hiperspektral Algılayıcılar

Hiperspektral algılayıcılar uzaktan algılama alanında kullanıldıkları havada stabil kalabilen araçlara entegre edilerek kullanılmaktadır. Bunun temel nedeni hiperspektral algılayıcıların algılama esnasında farklı filtreler ile görüntü elde etmesidir. Algılayıcının bulunduğu hava aracındaki en ufak sarsıntı görüntülerde kaymaya/bozulmaya ve bantların birbiri üstüne oturmamasına sebep olabilmektedir. Hali hazırda kullanılan ve daha önce kullanılmış hiperspektral algılayıcılar Tablo 1.1 ve Tablo 1.2’ de sunulmuştur [1]. Bu algılayıcılardan bir kısmı askeri bir kısmı ise ticari uygulamalar için kullanılmaktadır. Ayrıca bu algılayıcılardan elde edilen bazı görüntüler, genel kullanıma etiketli veri kümeleri olarak literatürde kullanılmaktadır. Tablolarda algılayıcıların ismi, üretici şirket, algılayıcının üretebildiği bant sayısı ve spektral çalışma aralığı verilmiştir. Hiperspektral görüntülerde diğer uzaktan algılama teknolojilerinde olduğu gibi algılayıcı görüntülenen sahnedeki ne kadar uzakta uzamsal çözünürlüğü o kadar düşüktür. Bu nedenle uydu üzerinde bulunan algılayıcılardan elde edilen görüntülerin uzamsal çözünürlükleri uçak ile elde edilen görüntülerin uzamsal çözünürlüklerine görece daha düşüktür.

Tablo 1.1 Uydu üzerindeki hiperspektral algılayıcılar [1]

Uydu Algılayıcıları	Üretici	Bant Sayısı	Spektral Aralık
FTHSI (MightySat II)	Air Force Research Lab.	256	0.35-1.05 μm
Hyperion (EO-1)	NASA	220	0.4-2.5 μm
CHRIS-Compact High Resolution Imaging Spectrometer- (PROBA)	ESA (European Space Agency)	maksimum 62	0.41-1.05 μm
ALI – Advanced Land Imager – (EO-1)	NASA	315	0.4-2.5 μm

Tablo 1.2 Hava aracı üzerindeki hiperspektral algılayıcılar [1]

Hava Aracı Algılayıcıları	Üretici	Bant Sayısı	Spektral Aralık
AAHIS (Advanced Aitborne Hyperspectral Imaging Sensors)	STI Industries	288	0.4-0.8 μm
AHI (Airborne Hyperspectral Imager)	University of Hawaii R&D	210	7.9-11.5 μm
AISA (Airborne Imaging Spectrometer)	Specim Spectral Imaging	maksimum 288	1.2-2.4 μm
Argus	HyVista Corporation	maksimum 400	0.37-2.5 μm

APEX (Airborne Prism Experiment)	ESA (European Space Agency)	maksimum 300	0.38-2.5 μm
ARCHER (Airborne Real-time Cueing Hyperspectral Enhanced Reconnaissance)	NovaSol Corp-Civil Air Patrol	512	0.5-1.1 μm
ARES	DLR	128 32	0.4-2.5 μm 8-12 μm
AVIRIS (Airborne Visible Infrared Imaging Spectrometer)	NASA Jet Propulsion Lab.	224	0.4-2.5 μm
CASI (Compact Airborne Spectrographic Imager)	ITRES Research Ltd.	maksimum 228	0.4-1.05 μm
COMPASS	Army Night Vision and Electronic Sensors Directorate (NVESD)	384	0.4-2.35 μm
DAIS 7915 (Digital Airborne Imaging Spectrometer)	GER Corporation	VIS/NIR (32), SWIR1 (8), SWIR2 (32), MIR (1), TIR (6)	VIS/NIR (0.43-1.05 μm), SWIR1 (1.5-1.8 μm), SWIR2 (2.0-2.5 μm), MIR (3.0-5.0 μm), TIR (8.0-12.0 μm)

DAIS 21115 (Digital Airborne Imaging Spectrometer)	GER Corporation	VIS/NIR (76), SWIR1 (64), SWIR2 (64), MIR (1), TIR (6)	VIS/NIR (0.40-1.0 μm), SWIR1 (1.0-1.8 μm), SWIR2 (2.0-2.5 μm), MIR (3.0-5.0 μm), TIR (8.0-12.0 μm)
EPS-H (Environmental Protection System)	GER Corporation	VIS/NIR (76), SWIR1 (32), SWIR2 (32), TIR (12)	VIS/NIR (0.43-1.05 μm), SWIR1 (1.5-1.8 μm), SWIR2 (2.0-2.5 μm), TIR (8.0-12.5 μm)
HYDICE (Hyperspectral Digital Imagery Collection Experiment)	Naval Research Lab.	210	0.4-2.5 μm
HyMap	Integrated Spectronics	100-200	0.45-2.48 μm
MIVIS (Multispectral Infrared and Visible Spectrometer)	Sensytech Corporation	102	0.43-12.7 μm
OMIS	SITP	128	0.4-12.5 μm
PHI	SITP	244	0.4-1.0 μm
PROBE-1	Earth Search Sciences Inc.	128	0.4-2.5 μm
ROSIS (Reflective Optics System Imaging Spectrometer)	DLR (Deutschen Zentrums für Luft und Raumfahrt)	128	0.43-0.86 μm

SASI (Shortwave Infrared Airborne Spectrographic Sensor)	ITRES Research Ltd.	160	0.85-2.45 μm
SEBASS	The Aerospace Corporation	128	2-14 μm
SFSI (Short Wavelength Infrared Full Spectrum Imager)	Canada Center for Remote Sensing	maksimum 120	1.23-2.38 μm
TRWIS III	TRW Corporation	384	0.3-2.5 m
VIFIS (Variable Interference Filter Imaging Spectrometer)	Aeroconcepts	64	0.42-0.87 m

1.3 Tezin Amacı

Yarı-güdümlü öğrenme teknikleri son yıllarda bir çok alanda olduğu gibi hiperspektral görüntülerde de sıklıkla kullanılmaya başlayan bir yaklaşımdır. Bunun temel nedeni veri etiketleme işleminin, özellikle hiperspektral verilerde, zor ve maliyetli bir işlem olmasıdır. Yarı-güdümlü öğrenme yöntemleri hem etiketli hem de etiketsiz verilerin bilgilerini kullanarak etiketsiz verileri çok az bir etiketli veri kümesi ile etiketlemeyi yani sınıf bilgisi atamayı hedefler.

Makine öğrenmesi yaklaşımlarında etiketli veriler literatürde kesin veri (groundtruth) olarak isimlendirilmektedir ve bu verinin elde edilmesi zor ve maliyetlidir. Hiperspektral görüntülerde etiketli veri elde etmek için sahneye ait görüntü alındıktan sonra çeşitli gürültü giderimi ve temizleme işlemleri uygulanır. Temizlenmiş veri üzerinde uzmanlar bölgesel olarak detaylı inceleme gerçekleştirir ve gerektiğinde yersel doğrulama işlemi gerçekleştirirler. Dolayısıyla etiketleme işlemi hem uzman sayısının kısıtlı olmasından hem de yapılan işin emek yoğun bir çalışma olmasından dolayı zor ve maliyetli bir işlemdir. Bu nedenle her durumda eğitici öğrenme yöntemlerinin kullanabileceği yeterli sayıda etiketli veri bulunmaması muhtemeldir. Diğer alanlarda olduğu gibi hiperspektral görüntüleme alanında da az sayıdaki etiketli veri ile sınıflama yapılması ihtiyacı ortaya çıkmaktadır. Bu sorunun üstesinden gelebilmek için yarı-güdümlü öğrenme yöntemleri kullanılmaktadır. Bu yöntemlerin temel işleyiş yapısından etiketli ve etiketsiz örneklerinin bilgilerinin beraber kullanılması ile başarılı bir sınıflama amaçlanmaktadır. Geleneksel yaklaşımlardan olan DVM ve YSA temel olarak iki fazdan oluşmaktadır. İlk aşamada etiketli verilerden

bir model elde edilir ve ikinci aşamada bu model kullanılarak etiketsiz veriler etiketlenir. Fakat yeterince etiketli veri olmadığı durumlarda bu geleneksel yaklaşımlar kullanılamaz hale gelmektedir.

Geleneksel yaklaşımlardan eğiticişiz öğrenme diğler bir deyişle kümeleme veriler arasındaki karakteristik bilgiyi sınıf bilgisi olmadan araştırmaktadır. Kümeleme esnasında herhangi bir veriye ait sınıf bilgisi yoktur. Bu nedenle, veri kümesindeki örneklerin öznitelik uzayındaki ilişkilerini bulmaya ve buradan bir sonuca ulaşmaya çalışır. Diğler bir geleneksel yaklaşım olan kümelemede ise veri kümesine ait sınıf bilgisi bulunmaktadır. Bu yaklaşımda ise veri kümesindeki örneklerin sınıf bilgisi kullanılarak sınıfların genel karakteristiğı yani her sınıfa ait bir tanım araştırılır. Daha önceleri birbirinden net çizigiler ile ayrı yaklaşımlar olarak tanımlanan kümeleme ve sınıflama son yıllarda birbiri içinde kullanılarak yarı-güdümlü öğrenme (semi-supervised learning) kavramı ortaya çıkmıştır.

Bu tez çalışmasının amacı az sayıda etiketli veri bulunan hiperspektral görüntülerin yarı-güdümlü olarak sınıflandırılmasıdır. Hiperspektral görüntülerde herbir örneğın bir hiperspektral imzası olduğı için etiketsiz veri bilgisinin etiketleme işleminde kullanılması elzemdir. Çalışmada, geleneksel yaklaşımlardan graf tabanlı sınıflama, destek vektör makineleri ile sınıflama, seyrek gösterim sınıflayıcısı gibi yöntemlerin yanında derin öğrenme tabanlı öznitelik çıkarımı, yarı-güdümlü destek vektör makineleri ve yarı-güdümlü seyrek gösterim sınıflayıcıları kullanılmıştır. Ayrıca hiperspektral görüntüler için yarı-güdümlü öğrenme alt yapısı oluşturulmuştur.

1.4 Hipotez

Geleneksel makine öğrenmesi yaklaşımlarında etiketli veri bilgisini kullanan sınıflayıcılar ile etiketsiz verileri kullanan kümeleme yöntemleri net bir şekilde ayrılmıştır. Veri etiketlemenin iş gücü ve zaman açısından maliyetinden dolayı son yıllarda az sayıda etiketli veri ile sınıflama problemine çözüm aranmıştır. Hem etiketli hem de etiketsiz verilerin gücünü beraber kullanan yöntemlere yarı-güdümlü öğrenme teknikleri ismi verilmiştir. Hiper spektral görüntülerin etiketlenmesinde yer doğrulaması gerektiğı için diğler alanlara oranla etiketli veri çok daha maliyetlidir. Buradan yola çıkarak yarı-güdümlü öğrenme yöntemlerinin hiperspektral görüntülerde bulunan kısıtlı etiketli örnek problemine çözüm olabileceğı düşünölmüştür ve farklı yöntemler kullanarak bu yönde çeşitli yaklaşımlar geliştirilmiştir.

Bu tez kapsamında birden fazla yarı-güdümlü sınıflama sistemi önerilmiştir. Bu sistemler verinin ele alınmasından verilerin yarı-güdümlü olarak sınıflanmasına kadar

olan tüm aşamaları içerir. Her bir sistemin farklı sistem akışı olduğu için sistemlerin aşağıdaki gibi 3 alt başlık altında ayrı ayrı incelenmesi planlanmıştır.

1.4.1 Temel Artımsal Yarı-Güdümlü Öğrenme

Önerilen yöntemde amaçlanan sınıflandırma sistemi temel olarak iki ana bölümden oluşmaktadır. İlk kısım olan yarı-güdümlü öğrenmede artımsal bir model benimsenmiştir ve temel amaç az sayıdaki etiketli veriyi daha başarılı bir model oluşturabilmek için kullanmaktır. İkinci aşama olan sınıflandırma bölümünde DVM ve seyrek öğrenme sistemine dayanan birleştirilmiş bir yapı oluşturularak gürbüz bir sınıflayıcı hedeflenmiştir.

1.4.2 Graf Tabanlı Yarı-Güdümlü Öğrenme

Önerilen yöntemde amaçlanan sınıflandırma sistemi temel olarak iki ana bölümden oluşmaktadır. İlk kısım olan yarı-güdümlü öğrenmede graf tabanlı bir yapı kurulmuştur. Burada grafın kendi kendine büyümesi ile etiketli verinin artırılması hedeflenmiştir. İkinci aşama olan sınıflandırma bölümünde DVM, çekirdek tabanlı seyrek öğrenme ve derin öğrenme sistemine dayanan birleştirilmiş bir yapı oluşturularak gürbüz bir sınıflayıcı hedeflenmiştir.

1.4.3 Derin Öğrenme Tabanlı Yarı-Güdümlü Öğrenme

Bu bölümde son yıllarda çok revaçta olan derin öğrenme(deep learning) yöntemi temel alınarak çalışmalar gerçekleştirilmiştir. Derin öğrenme kullanıma ilk olarak nesne tanımda başarısını kanıtlamış olan Alexnet ve VGG hazır ağlarını kullanarak başlanmıştır fakat nesne tanıma problemi ile hiperspektral veri sınıflamanın farklılığı ve bahsedilen ağların (özellikle VGG) hesaplama maliyetlerinin yüksekliğinden dolayı yapılan çalışmaların analizi sonrasında vazgeçilmiştir.

Derin öğrenmede ağ yapısındaki parametre fazlalığından dolayı veri miktarının fazla olması gerekmektedir. Tüm alanlarda olduğu gibi hiperspektral görüntü işleme alanında da etiketli veri kısıtı temel problemlerden biridir. Bu problemin üstesinden gelmek için transfer öğrenme (transfer learning) ortaya atılmıştır. Transfer öğrenmede temel olarak amaç hazır ağ modelinin son katmanı olan sınıflama katmanının değiştirilerek yeni bir probleme eğitilmiş bir modelin uyarlanmasıdır.

Geliştirilen sistemde yeni bir derin model tasarımı ve eğitimi gerçekleştirilmiştir. Eğitilmiş model üzerinde transfer öğrenme gerçekleştirilerek, ince ayar yapılan modelden öznitelik çıkarım işlemi gerçekleştirilmiştir. Çıkarılan öznitelikler

üzerinde yarı-güdümlü seyrek gösterim sınıflayıcısı ve yarı-güdümlü destek vektör makineleri ile yarı-güdümlü öğrenme gerçekleştirilmiştir. Öznitelik çıkarma işlemi gerçekleştirilmeden önce hesaplama maliyeti açısından kullanılabilir olmayan bu yarı-güdümlü öğrenme yöntemleri kullanılabilir hale gelmiştir.

2 Hiperspektral Veri Kümeleri

2.1 Rosis Pavia Üniversitesi Veri Kümesi


İtalya'ın Pavia şehrinde bulunan Pavia Üniversitesi'nin görüntüsünün bulunduğu veri kümesi ROSIS-03 (Reflective Optics System Image Spectrometer) hiperspektral algılayıcısıyla elde edilmiştir. 430 - 860 nm arasındaki bantlardan oluşan veri kümesi algılayıcı tarafından elde edildiğinde 115 bant içerecek şekilde oluşturulmuştur. Fakat genel kullanıma açık olan bu veri kümesindeki bazı fazla gürültülü bantlar atılarak 103 bantlı haliyle kullanılmaktadır. Veri kümesi Alman Hava Ajansı (DLR) tarafından oluşturulmuştur.

Tablo 2.1 Rosis Pavia Üniversitesi eğitim ve test örnekleri bilgileri

Sınıf İsimleri	Örnekler	
	Eğitim	Test
Ağaç	524	3064
Asfalt	548	6631
Zift	375	1330
Çakıl	392	2099
Metal Levha	265	1345
Gölge	231	947
Tuğla	514	3682
Çimen	540	18649
Toprak	532	5029
Toplam	3921	42776

Genel kullanıma açık olan Pavia Üniversitesi verisi 9 adet etiketli sınıfa sahiptir. Sınıflama uygulamaları için üretilen veri kümesinde her sınıfa ait eğitim ve test örnekleri ayrı ayrı işaretlenmiştir fakat eğitim örneklerinden bazıları test kümesi içinde de bulunmaktadır. 610 satır ve 340 sütundan oluşan veri kümesinin uzamsal çözünürlüğü 1.3 metredir. Hiperspektral veri kümelerinde bu yüksek bir uzamsal çözünürlüktür. Bu nedenle tek bir sınıfın bulunduğu saf pikseller bu veri kümesinde bulunmaktadır. 3921 eğitim ve 42776 test örneğinin bulunduğu veri kümesinde ağaç,

asfalt, zift, çakıl, metal tabaka, gölge, tuğla, çimen, toprak sınıfları bulunmaktadır. Pavia Üniversitesi sahnesine ait yapay renkli görüntü Şekil 2.1’ de görülmektedir [147]. Ayrıca veri kümesine ait etiketli örneklerin dağılım bilgisi Tablo 2.1’ de detaylı bir şekilde verilmiştir.



Şekil 2.1 Rosis Pavia Üniversitesi verisi
(a) yapay renkli görüntü (b) eğitim örnekleri (c) test örnekleri

2.2 HYDICE DC Mall Veri Kümesi


Veri kümesi Washington’ da bulunan DC Mall üzerinden Hyperspectral Digital Imagery Collection Experiment (HYDICE) optik algılayıcısı ile elde edilmiştir [148]. Temel olarak kümeleme analizleri için kullanılması öngörülen veri kümesinde 7 etiketli sınıfa ait toplam 8079 etiketli örnek bulunmaktadır. Hiper spektral sahne 1208 satır ve 307 sütundan oluşmaktadır. Hiper spektral algılayıcıdan elde edildiği halinde 210 spektral bant bulunan veri kümesindeki su buharından fazla etkilenen ve yüksek gürültülü bantlar çıkarıldıktan sonra 191 bant bulunmaktadır. Veri kümesi azaltılan bant sayısı ile analizlerde kullanılmaktadır. Veri kümesinde bulunan spektral bantlar 0.4 - 2.4 μm dalga boyu aralığında bulunmaktadır.

Hiper spektral sahneye ait etiketli örneklerde çatı, sokak, patika, çim, ağaç, su ve gölge sınıfları bulunmaktadır ve bu sınıflara ait detaylı bilgi Tablo 2.2’ de verilmiştir. Hiper spektral sahneye ait spektral bantlarla oluşturulan yapay görüntü ve etiketli örneklerin bulunduğu yer-gerçekliği görüntüsü Şekil 2.2’ de görülmektedir. HYDICE

Tablo 2.2 HYDICE DC Mall etiketli örnek bilgileri

Sınıf İsimleri	Etiketli Örnek Sayısı
Çatı	3834
Sokak	416
Patika	175
Çim	1928
Ağaç	405
Su	1224
Gölge	97
Toplam	8079

DC Mall verisinin uzamsal çözünürlüğü yaklaşık 2.8 metre olduğu için uzamsal açıdan yüksek çözünürlüğe sahip bir veri kümesidir.



Şekil 2.2 HYDICE DC Mall verisi
(a) yapay renkli görüntü (b) yer-gerçekliği görüntüsü

2.3 Aviris Indian Pines Veri Kümesi


Indian Pines veri kümesi en eski etiketli veriye sahip hiperspektral veri kümelerinden biri olduğu için literatürdeki çalışmalarda referans veri kümesi olarak oldukça fazla kullanılmaktadır. Hiperspektral sahne 1992 yılında Indiana eyaletinin kuzeybatısından alınan görüntüden oluşmaktadır [149]. 145 satır ve 145 sütundan oluşan hiperspektral sahne hiperspektral algılayıcının oluşturduğu haliyle 224 banttan oluşmaktadır. Veri kümesinin spektral bantları 0.4 - 2.5 μm spektral aralıktadır. Su buharından etkilenen ve yüksek oranda gürültüye sahip bantlar (104–108, 150–163 ve 220. bantlar) çıkarıldıktan sonra analizlerde kullanılan haliyle veri kümesi 200 banttan oluşmaktadır. Veri kümesine ait spektral bantlardan oluşturulmuş yapay görüntü ve genel kullanıma sunulmuş kesin referans haritası Şekil 2.3 ile verilmiştir.

Tablo 2.3 Indian Pines verisi etiketli örnek bilgileri

Sınıf İsimleri	Etiketli Örnek Sayısı
Alfalfa	46
Corn-notill	1428
Corn-mintill	830
Corn	237
Grass-pasture	483
Grass-trees	730
Grass-pasture-mowed	28
Hay-windrowed	478
Oats	20
Soybean-notill	972
Soybean-mintill	2455
Soybean-clean	593
Wheat	205
Woods	1265
Buildings-Grass-Trees-Drives	386
Stone-Steel-Towers	93
Toplam	10249

Etiketli verilerin bulunduğu yer-gerçekliği verisi bulunan genel kullanıma açık veri kümesinde 16 sınıf bulunmaktadır. Fakat bazı sınıflardan çok az sayıda örnek bulunması sebebiyle az sayıda örnek bulunan sınıfların çıkarılması ile 9 sınıflı kullanımı da literatürde mevcuttur. Veri kümesinde tek bir sınıftan oluşan odun, çim, çim-odun, mısır, bina, çim, ağaç sınıfları ile birden fazla sınıftan oluşan karışık sınıflar da bulunmaktadır. Karışık sınıflar bulunması sebebiyle zorlayıcı bir veri kümesi haline gelmektedir. Veri kümesindeki sınıflara ait detaylı dağılım bilgisi Tablo 2.3 ile verilmiştir. Aviris Indian Pines verisinin uzamsal çözünürlüğü yaklaşık 20 metre olduğu için uzamsal açıdan düşük çözünürlüğe sahip bir veri kümesidir. Bundan dolayı

bir sınıfa ait saf piksel oranı diğer veri kümelerine oranla düşüktür.



Şekil 2.3 Aviris Indian Pines verisi

(a) Görüntü uzayında RGB üç kanal yapay görüntü (b) Kesin referans haritası


2.4 Aviris Salinas Veri Kümesi

Kaliforniya’ da bulunan Salinas Vadisi’ nin görüntüsünün alınması ile elde edilen veri kümesi Aviris hiperspektral sensörü ile oluşturulmuştur. Bu nedenle hiperspektral sensörden elde edildiği haliyle 224 hiperspektral banta sahip bir veri kümesidir. Aynı sensörden alınan Indian Pines veri kümesinde olduğu gibi su buharından etkilenen ve gürültü oranı yüksek olan bantlar çıkarıldığında (108-112, 154-167, 224) 204 hiperspektral bantlı hali analizlerde kullanılmıştır [150]. Yer-gerçekliği verisinde Indian Pines veri kümesindeki gibi 16 sınıf bulunmaktadır ve bu sınıflar sebze, çıplak toprak ve üzüm bağ alanları gibi sınıflardan oluşmaktadır. Veri kümesindeki etiketli örnekler ait detaylı dağılım ve isim bilgisi Tablo 2.4’ te sunulmuştur. Hiperspektral sahne 512 satır ve 217 sütundan oluşmaktadır. Sahneye ait spektral bantlardan oluşturulmuş yapay renkli görüntü ve etiketli örnekler ait yer-gerçekliği haritası Şekil 2.4’ de görülmektedir.

Aviris Salinas verisinin uzamsal çözünürlüğü yaklaşık 3.7 metre olduğu için uzamsal açıdan yüksek çözünürlüğe sahip bir veri kümesi olarak tanımlamak mümkündür. Uzamsal çözünürlüğü yüksek olan veri kümesinin tüm sınıfları neredeyse saftır. Ayrıca tarım bölgesinden alınan bir veri kümesi olduğu ve ekili alanların birbirinden kesin sınırlar ayrı olması nedeniyle farklı madde cinslerini birbiri içinde bulunduran sınıflar yoktur.

Tablo 2.4 Salinas verisi etiketli örnek bilgileri

Sınıf İsimleri	Etiketli Örnek Sayısı
Brocoli_green_weeds_1	2009
Brocoli_green_weeds_2	3726
Fallow	1976
Fallow_rough_plow	1394
Fallow_smooth	2678
Stubble	3959
Celery	3579
Grapes_untrained	11271
Soil_vinyard_develop	6203
Corn_senesced_green_weeds	3278
Lettuce_romaine_4wk	1068
Lettuce_romaine_5wk	1927
Lettuce_romaine_6wk	916
Lettuce_romaine_7wk	1070
Vinyard_untrained	7268
Vinyard_vertical_trellis	1807
Toplam	54129



(a)



(b)

Şekil 2.4 Salinas verisi

(a) Görüntü uzayında RGB üç kanal yapay görüntü (b) Kesin referans haritası


2.5 Pavia Center Veri Kümesi

İtalya' nın Pavia şehrinin merkezinin görüntüsünün ROSIS-03 (Reflective Optics System Image Spectrometer) hiperspektral sensörü ile görünütüsünün alınması ile elde edilen veri kümesi orijinal haliyle 115 spektral bant içermektedir. Su buharının bulunduğu ve gürültü oranı yüksek bantlar çıkarıldıktan sonra 102 bant bulunan hali literatürde genel olarak kullanılmaktadır. Hiperspektral sahneye ait veri Alman Hava Ajansı (DLR) tarafından oluşturulmuştur. Veri kümesine ait spektral bantlar 430 - 860 nm spektrum aralığında bulunmaktadır.

Tablo 2.5 Rosis Pavia Center verisi etiketli örnek bilgileri

Sınıf İsimleri	Etiketli Örnek Sayısı
Su	65971
Ağaç	7598
Asfalt	3090
Tuğla	2685
Zift	6584
Kiremit	9248
Gölge	7287
Çimen	42826
Toprak	2863
Toplam	148152

Veri kümesi 1096 satır ve 1096 sütundan oluşmaktadır. Genel kullanım için üretilen veri kümesinde 9 etiketli sınıf bulunmaktadır. Bu sınıflar su, ağaç, asfalt, tuğla, zift, kiremit, gölge, çimen ve toprak sınıflarıdır. Etiketli sınıflara ait toplam 148152 etiketli örnek bulunmaktadır. Sınıflara ait örnek dağılımı Tablo 2.5' de verilmiştir. Veri kümesindeki spektral bantlardan oluşturulan yapay renkli görüntü ve yer-gerçekliği haritası Şekil 2.5' de görülmektedir. Pavia Center verisinin uzamsal çözünürlüğü 1.3 metre olduğu için uzamsal açıdan yüksek çözünürlüğe sahip bir veri kümesidir. Fakat şehir yapılarının bulunduğu bir bölgeden alınan bir görüntü olduğu için sınıflarda karışık piksellerin olması muhtemeldir.



Şekil 2.5 Pavia Center verisi
(a) Görüntü uzayında RGB üç kanal yapay görüntüsü (b) Kesin referans haritası

Önerilen yöntemde amaçlanan sınıflandırma sistemi temel olarak iki ana bölümden oluşmaktadır. İlk kısım olan yarı-güdümlü öğrenmede artımsal bir model benimsenmiştir ve temel amaç az sayıdaki etiketli veriyi daha başarılı bir model oluşturabilmek için kullanmaktır. İkinci aşama olan sınıflandırma bölümünde DVM ve seyrek öğrenme sistemine dayanan birleştirilmiş bir yapı oluşturularak gürbüz bir sınıflayıcı hedeflenmiştir.

3.1 Yarı-Güdümlü Öğrenme

Yarı-güdümlü öğrenmede temel amaç az sayıdaki etiketli veri ile çok sayıdaki etiketli veriden elde edilebilecek başarıyı elde edebilmek veya yakınsayabilmektir. Bunun sebebi etiketli verilerin elde edilmesinin diğer tüm uzaktan algılama uygulamalarında olduğu gibi hiperspektral görüntüler için de zorlu ve masraflı bir işlem olmasıdır.

3.1.1 Birinci Yarı-Güdümlü Öğrenme Yaklaşımı

Yarı-güdümlü öğrenme iki temel aşamadan oluşmaktadır. Bunlardan ilki etiketli verilerin seçimi; ikincisi ise yeni etiketlenecek verilerin hangi kurala göre seçileceğidir. Bu çalışmada etiketli verilerin seçimi aşamasında başarıyı artırmak için en fazla kazanç sağlayacak tarzda etiketli verilerin seçilmesi hedeflenmiştir. Bu işlemi gerçekleştirmek için de eğitim kümesi etiket bilgisi kullanılmadan k-ortalamlar yöntemi kullanılarak kümelendir. Her sınıftan belli sayıda etiketli veri kullanılarak ilklendirme gerçekleştirilir. Örneğin her sınıftan 5 etiketli örnek seçilecekse, her sınıf kendi içinde 5 kümeye ayrılır. Her kümenin kendi içinde 10 kere rastgele örnek seçimi yapılır ve bu 10 rastgele örneğin ortalamasına en yakın örnek seçilerek etiketli veri olarak kullanılır. İkinci aşamada artımsal bir model baz alınmıştır. Artımsal modelde her seferinde yeni bir etiketsiz veri etiketlenir ve bir sonraki adım için eğitim kümesine katılır. Her seferinde hali hazırda bulunan etiketli eğitim kümesindeki örneklerden herhangi birine en yakın olan test örneği seçilerek eğitim kümesine katılır. Yani

güvenilirlik skoru en yüksek olan etiketsiz veri etiketlenerek eğitim kümesine katılır. Bu işlem en yakın komşuluk kuralı referans alınarak gerçekleştirilmiştir. YGÖ başarımı ilklendirmede kullanılan etiketli veri sayısı ile doğru orantılıdır. Etiketlenen veri sayısı ne kadar çoksa yer-gerçekliğine o derece yakın öğrenme sonuçları elde edilmiş olur.

3.1.2 İkinci Yarı-Güdümlü Öğrenme Yaklaşımı

Bu yarı-güdümlü öğrenme yaklaşımı, yaklaşım 1' den sadece ilk seçilecek etiketli örneklerin seçimi noktasında ayrılır. Bu yöntemde de etiketli verilerin seçimi aşamasında başarımı artırmak için en fazla kazanç sağlayacak tarzda etiketli verilerin seçilmesi hedeflenmiştir. Bu işlemi gerçekleştirmek için de eğitim kümesi etiket bilgisi kullanılmadan k-ortalamlar yöntemi veya subtractive-clustering (eksiltici-kümeleme) kullanılarak kümelendirir. Her kümenin son durumdaki merkezine en yakın eğitim örneği etiketli örnek olarak seçilerek ilklendirilir. İkinci aşaması yaklaşım 1 ile aynı şekilde uygulanmaktadır. YGÖ başarımı ilklendirmede kullanılan etiketli veri sayısı ile doğru orantılıdır. Etiketlenen veri sayısı ne kadar çoksa yer-gerçekliğine o derece yakın öğrenme sonuçları elde edilmiş olur.

Eksiltici kümeleme (subtractive clustering - SC), dağ (mountain) kümeleme yönteminin özelleşmiş bir formudur. SC tekniği temel olarak verilen bir radius (yarıçap) parametresini kullanarak veri alanının en yoğun olduğu alanları bulur. Algoritma her örneği bir aday küme merkezi olarak kabul eder. Her bir aday küme merkezinin yoğunluk potansiyeli $M(x_i) = \sum_{j=1}^n e^{-\alpha \|x_i - x_j\|^2}$ fonksiyonu ile hesaplanır. Her merkez için potansiyelin hesaplanmasının ardından, en yüksek x_i^{max} potansiyeline sahip örnek $M_i^{max} = \max_i(M(x_i))$ eşitliğince bulunur. Burada M_i^{max} değeri maksimum potansiyeli ifade etmektedir. Bir sonraki en yüksek potansiyelli küme merkezini bulmak için x_i^{max} 'nin etrafındaki verilen çap içinde kalan örnekler (3.1) eşitliğince eksiltir.

$$\hat{M}^j(x_i) = \hat{M}^{j-1}(x_i) - M_{j-1}^{max} \sum_{j=1}^n e^{-\beta \|x_i - x_{j-1}^{max}\|^2} \quad (3.1)$$

3.1.3 Üçüncü Yarı-Güdümlü Öğrenme Yaklaşımı

Bu yarı-güdümlü öğrenme yaklaşım 2' den farklı olarak hiçbir sınıf bilgisi kullanılmamaktadır. Yani yaklaşım 1 ve yaklaşım 2' de etiketli örnek ilklendirmesi yapılırken her sınıftan belli sayıda etiketli veri kullanılarak ilklendirme gerçekleştirilir. Örneğin her sınıftan 5 etiketli örnek seçilecekse, her sınıf kendi içinde 5 kümeye ayrılır. Fakat bu yöntemde her sınıf için ilklendirilecek örnek sayısı seçimi yoktur.

Sadece ilklendirilecek toplam etiketli örnek sayısı seçimi vardır. Dolayısıyla her sınıftan farklı sayıda etiketli örnek sayısı gelmesi mümkündür. Bu yöntemde de yine diğerleri gibi etiketli verilerin seçimi aşamasında başarıyı artırmak için en fazla kazanç sağlayacak tarzda etiketli verilerin seçilmesi hedeflenmiştir. Bu işlemi gerçekleştirmek için de eğitim kümesi etiket bilgisi kullanılmadan k-ortalamlar yöntemi kullanılarak kümelenir. Her kümenin son durumdaki merkezine en yakın eğitim örneği etiketli örnek olarak seçilerek ilklendirilir. İkinci aşaması yaklaşım 2 ile aynı şekilde uygulanmaktadır. YGÖ başarıyı ilklendirmede kullanılan etiketli veri sayısı ile doğru orantılıdır. Etiketlenen veri sayısı ne kadar çoksa yer-gerçekliğine o derece yakın öğrenme sonuçları elde edilmiş olur.

K-ortalamlar yönteminde, d boyutlu $X = x_i, i = 1, \dots, n$ veri kümesinin $C = c_k, k = 1, \dots, K$ K adet kümeye ayrılacağını varsayalım. K-ortalamlar kümeleme yöntemi, bir kümenin empirik ortalaması ile küme örnekleri arasındaki karesel hatanın en aza indirilmesini amaçlamaktadır. μ_k 'nın c_k kümesinin ortalaması olduğunu varsayalım ve μ_k ile c_k kümesine ait tüm örneklerin karesel hatası (3.2) eşitliğince hesaplanır.

$$J(c_k) = \sum_{x_{ik}} \|x_i - \mu_k\|^2 \quad (3.2)$$

K-ortalamlar yönteminin hedefi toplam karesel hatayı (3.3) eşitliği yardımıyla minimize etmektir.

$$J(C) = \sum_{k=1}^K \sum_{x_{ik}} \|x_i - \mu_k\|^2 \quad (3.3)$$

Amaç işlevini minimize etmek NP-hard bir problemdir [151]. Açgözlü bir yaklaşıma sahip olan K-ortalamlar algoritması, çalışmalar iyi dağılmış bir veri kümesinde yöntemin global optimumu bulabileceğini gösterse de, lokal optimumda takılma ihtimali de vardır [152]. K-ortalamlar yönteminde küme sayısı arttıkça karesel hata düşer hatta $K = n$ olduğunda $J(C) = 0$ olur. K-ortalamlar yönteminin temel adımları aşağıdaki gibidir [2]:

- Başlangıçta rastgele K adet küme merkezi seçilir ve küme aidiyetleri değişmeyene kadar 2. ve 3. adımlar tekrarlanır.
- Her örnek kendisine en yakın küme merkezi ile ilişkilendirilir.
- Yeni küme merkezleri hesaplanır.

3.1.4 Dördüncü Yarı-Güdümlü Öğrenme Yaklaşımı

Bu yöntem, yaklaşım 2' ye aynı şekilde etiketli veri ilklendirmesini gerçekleştirir. Bu işlemi gerçekleştirmek için de her sınıftan k sayıdaki etiketli örnek seçimi için, eğitim kümesi etiket bilgisi kullanılmadan k -ortalamalar yöntemi kullanılarak kümelenir. Her kümenin son durumdaki merkezine en yakın eğitim örneği etiketli örnek olarak seçilerek ilklendirilir. İkinci aşamada ise diğer üç yöntemden farklı olarak iteratif k -nn yöntemi yerine cluster-kernel Sparse Representation Classifier (Küme Çekirdek Seyrek Gösterim Sınıflayıcısı - ckSRC) yöntemi ile YGÖ gerçekleştirilir. Seyrek gösterim sınıflayıcısından bir sonraki bölümde bahsedilecektir. Küme çekirdekleri yönteminin çalışma prensibinde veri belirlenen bir k sayısı kadar kümeye ayrılır. Daha sonra tüm örneklerin küme bilgisi ikişerli ikişerli karşılaştırılır. Bu karşılaştırma sonucunda örnekler aynı kümede ise 1 farklı kümede ise 0 atanır. Bu kümeleme ve karşılaştırma işlemi belirlenen m sayısı kadar tekrarlanır. Karşılaştırma sonuçları toplanır ve m sayısına bölünür. Burada elde edilen çekirdek bilgisi kullanacağımız çekirdek sınıflayıcı ile çekirdek matrisi seviyesinde birleştirilir. Bu yöntemde kümeleme için k -ortalamalar, çekirdek sınıflayıcı olarak da çekirdek seyrek gösterim sınıflayıcısı kullanılmıştır, ve bu şekilde YGÖ gerçekleştirilmiştir.


3.1.5 Beşinci Yarı-Güdümlü Öğrenme Yaklaşımı

Geliştirilen yöntem daha önce bahsedilen yaklaşım 2 ve yaklaşım 4' ün birleştirilmesi ile elde edilen kombine bir sistemdir. Yaklaşım 2' de başlangıçtaki etiketli veri sayısının yöntemin çalışmasına bir etkisi yoktur sadece başarıma etkisi olmaktadır. Fakat yaklaşım 4' te kullanılan seyrek gösterim sınıflayıcısının doğası gereği çok az sayıdaki etiketli örnekle yaklaşım 4' ün çalışması mümkün değildir. Bu neden geliştirilen sistem ile önce yaklaşım 2 ile etiketli veri sayısının artırılması, artırılan etiketli verilerin yaklaşım 4' te giriş olarak kullanılmasıyla her sınıftan etiketli tek bir örnek alınarak tüm eğitim kümesinin etiket bilgisinin öğrenilmesi mümkün hale gelmektedir. Aynı işlem sadece yaklaşım 2 kullanılarak gerçekleştirildiğinde YGÖ başarıma çok daha düşük olmaktadır.

3.2 DVM ve Seyrek Öğrenmenin Birleştirilmesi ile Sınıflandırma

Sınıflandırma sisteminde iki farklı sınıflayıcının birleştirilmesi hedeflenmiştir. Bunlardan ilki hiperspektral görüntü sınıflandırma alanında sıklıkla kullanılan DVM'dir. Diğeri ise daha çok hiperspektral ayrıştırma için kullanılan seyrek gösterim sınıflayıcısıdır. DVM temelde iki sınıflı, doğrusal-olmayan bir sınıflayıcı olmasına rağmen; çok sınıflı doğrusal-olmayan sınıflandırma, dışbükey optimizasyon ve yoğunluk tahmini problemlerini çözmek için de kullanılagelen eğitici bir

makine öğrenmesi yöntemidir. SGS, elde bulunan bir eğitim kümesinin doğrusal kombinasyonu ile yeni gelen bir test örneğinin ifade edilebileceğini kabul eden eğitici bir makine öğrenmesi yöntemidir. Temelde her bir sınıf için yakınsama hatasının çoğalan toplamına bakarak test örneğinin sınıflandırılması işlemini gerçekleştirir.



Şekil 3.1 Seyrek gösterim

YGÖ ile elde edilen eğitim kümesi çok sınıflı DVM ile radyal tabanlı fonksiyon (RBF) kullanılarak yüksek boyutlu uzaya taşınarak sınıflandırma gerçekleştirmiştir. İkili bir sınıflayıcı olan DVM çok sınıflı olarak kullanılırken “bir sınıfa karşı bir sınıf” stratejisi benimsenmiştir. Seyrek gösterim sınıflayıcısı, DVM gibi RBF uzayına taşınarak kullanılmıştır. Dolayısıyla kullanılan SGS, çekirdek (kernel) seyrekerim sınıflayıcısıdır. SGS sınıflandırması yapılırken eğitim pikseli (spektral imza) SGS sözlüğü için bir atom olarak kabul edilir. Atom, SGS sözlüğü oluşturulurken sözlüğü oluşturan her bir bileşene verilen isimdir. Daha sonra her sınıf için o sınıfa ait tüm pikseller alınarak bir alt sözlük oluşturulur ve her sınıf için gelen test pikseli için yakınsama hatası hesaplanır. En küçük yakınsama hatasına sahip sınıf test pikselinin sınıfı olarak kabul edilir. SGS yakınsaması hesaplanırken doğrusal kombinasyon vektörü olan w bulunurken L1 norm minimizasyon algoritmalarından olan Homotopy tekniği kullanılmıştır. Açıklayıcı görsel olarak verilen Şekil 3.1’ de eşitliğin sağ tarafında bulunan matris her sınıf için ayrı ayrı oluşturulan matristir. Yine eşitliğin sağ tarafında bulunan seyreker vektör, ağırlık vektörünü ifade etmektedir. Eşitliğin sol tarafındaki vektör ise yakınsama vektörüdür. Test pikseli ile yakınsama vektörünün farkından elde edilen hata için kullanılan eşik değeri olan λ parametresi $\lambda = 0.001$ olarak kullanılmıştır.

Seyrek gösterim sınıflayıcısının temel varsayımı, öznitelik uzayında aynı sınıfa ait örneklerin birbirine yakın olacağıdır [114]. C adet sınıfımız ve c . sınıfın $\{a_j^c\}_{j=1,\dots,N_c}$ ile ifade edilen N_c adet eğitim örneğinden oluştuğunu varsayalım. x , M boyutlu yeni bir hiperspektral piksel gözlemidir. Eğer x , c sınıfına ait bir örneğe hiperspektral öznitelik uzayında x ' in c sınıfının eğitim örneklerine yakın olması beklenir. x örneği, $\{a_j^c\}_{j=1,\dots,N_c}$ eğitim örneklerinin lineer bir kombinasyonu olarak ifade edilebilir:

$$\begin{aligned} x &\approx a_1^c w_1^c + a_2^c w_2^c + a_3^c w_3^c + \dots + a_{N_c}^c w_{N_c}^c \\ &= [a_1^c a_2^c a_3^c \dots a_{N_c}^c] [w_1^c w_2^c w_3^c \dots w_{N_c}^c] \\ &= a^c w^c \end{aligned} \quad (3.4)$$

(3.2) eşitliğinde a^c , Şekil 3.1' de gösterildiği gibi $M \times N_c$ boyutlu bir alt-sözlüktür. a^c nin sütunları c . sınıfa ait M boyutlu eğitim örneklerini ifade etmektedir. w^c ise x gözlemini oluşturmaya imkan sağlayan c . sınıfına ait ağırlık vektörünü göstermektedir. Diğer yandan x , C sınıfa ait C alt-sözlükten meydana gelebilir:

$$\begin{aligned} x &\approx a^1 w^1 + a^2 w^2 + a^3 w^3 + \dots + a^C w^C \\ &= [a^1 a^2 a^3 \dots a^C] [w^1 w^2 w^3 \dots w^C] \\ &= AW \end{aligned} \quad (3.5)$$

burada A , tüm sınıfların tüm örneklerinden oluşan $M \times N$ boyutlu sözlüğü temsil etmektedir. $N = \sum_{c=1}^C N_c$, ise tüm sınıflara ait örnek sayısını ifade eder.

Kullanılan seyrek gösterim sınıflayıcısında x , her bir C sınıfı için oluşturulur. Her sınıfa verilen a^c eğitim örnekleri için, $a^c w^c = x$ eşitliğini sağlayan uygun bir w^c seyrek vektörü (3.6) optimizasyon problemi çözülerek hesaplanır:

$$\hat{w} = \underset{w}{\operatorname{argmin}} \|w\|_0 \quad \text{subject to} \quad aw = x \quad (3.6)$$

Bu bir yakınsama problemi olduğu için, işin içine yakınsama hatası da katılmalıdır. Yakınsama hatası dahil edildiğinde (3.6) aşağıdaki hale gelir:

$$\hat{w} = \underset{w}{\operatorname{argmin}} \|w\|_0 \quad \text{subject to} \quad \|aw - x\| \leq \sigma \quad (3.7)$$

burada σ , geri çatma hatasını ifade etmektedir. $\hat{w}^c$, c sınıfına ait seyrek çözüm vektörü iken x , $\hat{w}^c$ 'nin karakteristiğine göre sınıflanabilir:

$$\epsilon^c(x) = ||x - a^c \hat{w}^c||_2, \quad c = 1, 2, 3, \dots, C \quad (3.8)$$

ϵ^c , verilen x vektörü için c . sınıf çözümünün yaklaşım hatasını (verilen x örneğinin c . sınıf eğitim örnekleriyle yeniden inşası arasındaki hata) ifade eder. Bu noktada x 'in etiket bilgisine minimum hatanın bulunması ile ulaşılır:

$$class(x) = argmin_{c=1,2,3,\dots,C} \epsilon^c(x) \quad (3.9)$$

Sistem birleştirilmesi, kullanılan her iki sınıflayıcının test sonuçlarının karşılaştırılmasıyla elde edilir. Her iki sınıflayıcı, sınıflama sonucunda aynı sınıfı işaret ediyorsa ortak sınıf sistem sonucu olarak kabul edilir. Bunun dışında sınıflayıcılar farklı sınıfları işaret ediyorsa, iki sınıflayıcının güvenilirlik skoruna bakılır, güvenilirlik skoru %90'ın üzerinde olan sınıflayıcının tahmini birleştirilmiş sistem başarımı olarak ele alınır. Fakat iki sınıflayıcı farklı sınıfları işaret ediyorsa ve güvenilirlik değerleri eşik değerinin altındaysa, test örneği için her iki sınıflayıcıdan 3 en-iyi sonuca bakılır ve karar seviyesi kaynaşımı (decision level fusion) gerçekleştirilir. Bu noktada her iki sınıflayıcı için 3 en-iyi sınıf sonuçları için güvenilirlik skoruna bakılır. DVM için bu güvenilirlik skoru ikili DVM'den çok sınıflı DVM'ye geçerken elde edilen birleşik olasılık hesabıdır ve bu olasılık $[0,1]$ arasına normalize edilir. SGS'de ise güvenilirlik skoru (3.10) eşitliğince hesaplanır. Bu eşitlikte Hata, verilen bir test örneği için hesaplanan sınıf hatasını temsil etmektedir. Daha sonra o test örneği için tüm sınıflara ait güvenilirlik skoru $[0,1]$ arasına normalize edilir.

$$Confidence \text{ (Güvenilirlik)} = 1 - Error \text{ (Hata)} \quad (3.10)$$

Sistem birleştirilmesi dışında bağımsız bileşen analizi (BBA) yapılarak sistem başarımları da değerlendirilmiştir. Böylece bantlardaki gürültünün veriden ayrılarak sistem başarımının artırılması hedeflenmiştir.

3.3 Deneysel Sonuçlar

Hedeflenen sınıflama sisteminin başarımının değerlendirilmesi için ROSIS Pavia Üniversitesi hiperspektral görüntüsü kullanılmıştır. Bu hiperspektral görüntü 610x340

boyutlarında olup, 103 spektral bant içermektedir. Bu veride güdümlü sınıflama için 9 sınıfa ait etiketli 3921 eğitim pikseli ve 42776 test pikseli bulunmaktadır.

3.3.1 Birinci Yaklaşım Sonuçları

Deneysel sonuçlar gerçekleştirilirken sistem başarımları dört farklı başlık altında incelenmiştir. Bunlardan ilki tüm bantlarda yarı-güdümlü öğrenme ve sistem birleştirilmesi ile alınan sonuçların sunumudur. İkincisi ise yine aynı şekilde tüm bantlarda YGÖ ve sistem birleştirilmesi ile BBA uygulanmış veri üzerinde elde edilen başarımlar ölçümleridir. Üçüncü ölçüm birinci ölçümle, dördüncü ölçüm de ikinci ölçümle aynı tarzda oluşturulmuştur; yalnız farklı olarak ölçümler gürültülü bantlar giderilip, en yüksek enformasyonu taşıyan bantların seçimi yapıldıktan sonra gerçekleştirilmiştir.

Yarı-güdümlü öğrenmede her sınıfa ait etiketli veri sayısı 5, 10, 15, 20, 30, 40, 50 olarak ilklendirilerek, toplamda sırasıyla 45, 90, 135, 180, 270, 360, 450 etiketli veri kullanılarak 3921 eğitim verisinin tamamının tekrar etiketlenmesi sağlanmıştır. Her sınıf için seçilen başlangıç etiketli veri sayısına göre eğitim verisinin YGÖ sonucu elde edilen doğru etiketleme başarımları sonucu Tablo 3.1’de görülmektedir. Beklendiği gibi başlangıçtaki etiketli örnek sayısı arttıkça eğitim kümesindeki örneklerin doğru sınıflandırılma başarımları da artmaktadır.

Tablo 3.1 Farklı örnek sayıları için YGÖ başarımları (%)

Örnek Sayısı	YGÖ Başarımları (%)
5x9	67.69
10x9	69.55
15x9	72.18
20x9	75.92
30x9	77.86
40x9	79.57
50x9	82.61

Tablo 3.2’de 5, 10, 15, 20, 30, 40, 50 etiketli örnek sayısına göre DVM, SGS ve birleştirilmiş sistem başarımları görülmektedir. Her sınıftan alınan 5 etiketli örneklerle alınan kombine sistem başarımları %70.14 olarak görülmektedir. Etiketli veri sayısı arttıkça DVM, SGS ve birleştirilmiş sistem başarımlarının arttığı görünmekle birlikte, Tablo 3.1’de 5 örneklerle elde edilen başarımlar ile 50 örneklerle elde edilen başarımlar farkı %15 olmasına karşılık, Tablo 3.2’deki başarımlar farkının yaklaşık %7.5 olarak göze çarpmaktadır. Burada dikkat edilmesi gereken husus, birinci tablo harici bütün deneylerin test verisi üzerinde gerçekleştirilmesidir. Ayrıca tabloda bulunan son sütunda DVM ve SGS’ nin daha başarılı bir şekilde birleştirilebildiğinde alınabilecek maksimum başarımlar ortaya

koyulmuştur.

Tablo 3.2 Farklı örnek sayıları için sınıflama başarımları sonuçları (%)

Örnek Sayısı	DVM	SGS	Birleştirilmiş Sistem (%)	DVM-SGS Olası Maksimum Başarım (%)
5x9	69.19	70.00	70.14	72.27
10x9	71.18	71.93	72.24	74.76
15x9	72.62	73.10	73.20	77.65
20x9	73.41	73.69	73.90	78.00
30x9	75.05	72.69	75.54	81.22
40x9	76.42	75.08	76.60	82.17
50x9	76.98	75.62	77.72	84.60

Etiketli örnek sayısının daha az olduğu denemelerde SGS, seyrek gösterimin dayandığı temelden dolayı hatalı eğitim örneklerine daha dayanıklı olduğu için daha başarılı sonuçlar vermektedir. Fakat etiketli örnek sayısının artmasıyla hatalı eğitim verisi sayısının azalmasıyla DVM sınıflayıcısı daha başarılı sonuçlar üretmektedir. Bu iki sınıflayıcının güven değerleri kullanılarak birleştirilmesiyle elde edilen birleştirilmiş sınıflayıcı, her iki sınıflayıcının da üstünde bir başarımın elde edilmesini sağlamaktadır.

Tablo 3.3 BBA ile farklı örnek sayıları için sınıflama başarımları sonuçları (%)

Örnek Sayısı	DVM	SGS	Birleştirilmiş Sistem (%)
5x9	68.66	69.52	69.75
10x9	74.85	71.98	74.91
15x9	75.69	72.85	75.80
20x9	76.21	73.23	76.32
30x9	76.95	73.97	77.03
40x9	77.03	74.39	77.71
50x9	78.23	75.56	78.31

Tablo 3.3’ te BBA özelliklerinin çıkarılması ile elde edilmiş olan sonuçlar görülmektedir (toplam 80 öznitelik). Sonuçlara baktığımızda DVM sınıflayıcısının başarımlarının genel olarak yükseldiği görülmektedir ve SGS’ nin başarımının az miktarda yükseldiği hatta bazı örnek sayılarında azaldığı görülmektedir. Bunun temel nedeni BBA ile gürültü bantların atılması esnasında SGS için çeşitliliğin azalmasıdır. Diğer yandan DVM’ nin başarımının göreceli olarak daha fazla artmasının nedeni gürültüye duyarlı bir sınıflayıcı olmasından kaynaklanmaktadır.

Hiperspektral görüntülemelerde bazı bantlar çok fazla gürültü içerdiği için sınıflama başarımları olumsuz etkilenecek şekilde başarımı düşmektedir. Bu nedenle deneysel olarak gürültülü bantlar atılıp, seçilen bant aralığında çalışıldığında sistemin

Tablo 3.4 Bant seçimi sonrası farklı örnek sayıları için sınıflama başarımları sonuçları (%)

Örnek Sayısı	DVM	SGS	Birleştirilmiş Sistem (%)
5x9	72.06	71.66	72.25
10x9	72.14	72.5	73.21
15x9	74.80	75.11	75.36
20x9	77.42	75.55	77.67
30x9	77.93	75.16	78.49
40x9	79.00	76.39	79.09
50x9	79.72	77.80	80.35

daha başarılı sonuçlar verdiği gözlemlenmiştir. Bu gözlem doğrultusunda [1-72] arası bantlar seçilerek sınıflama yapıldığında alınan başarımları sonuçları Tablo 3.4' te görülmektedir. Bant seçimi ile her sınıftan 50 etiketli örnek seçimiyle elde edilen sistem başarımları %80.35 gibi bant seçimi yapılmadan sadece DVM uygulanan sınıflandırma sonucunu aşan başarımları oranı yakalanmıştır. Etiketli örnek sayılarına göre başarımları artımı farklılık gösterse de bant seçimi yapılmamış sistemle karşılaştırıldığında genel olarak %2.5 oranında başarımları artımı sağlandığı gözlemlenmiştir.

Tablo 3.5 Bant seçimi ve BBA sonrası farklı örnek sayıları için sınıflama başarımları sonuçları (%)

Örnek Sayısı	DVM	SGS	Birleştirilmiş Sistem (%)
5x9	73.07	69.32	73.11
10x9	76.18	71.47	76.29
15x9	76.89	71.89	76.97
20x9	77.01	71.85	77.17
30x9	78.21	72.23	78.26
40x9	78.47	74.02	78.73
50x9	78.63	75.45	78.90

Tablo 3.3' te BBA'nın; Tablo 3.4' te ise bant seçiminin genel sistem başarımları ayrı ayrı artırdığı görülmektedir. Bu nedenle hem bant seçimi hem de BBA yapıldığında sistemin nasıl tepki verdiği Tablo 3.5' de incelenebilir. BBA ile bant seçimi birleştirilirken yine deneysel olarak bulunan, [5-84] bant aralığında kalan bantlar kullanılarak sınıflama yapılmıştır. Hem bant seçimi hem de BBA ayrı ayrı uygulandığında tüm etiketli örnek sayılarına genel olarak aynı şekilde etki etmiştir. Fakat ikisi beraber uygulandığında daha az etiketli örnek alındığında sistem başarımları diğer testlere göre daha fazla artarken, fazla sayıda etiketli örnek alınan durumlarda sistem başarımlarının az da olsa düştüğü gözlemlenmiştir. Ayrıca Tablo 3.5' de DVM

başarımının artarken SGS başarımının düştüğü de görülmektedir. Bunun nedeni hem BBA hem de bant seçimi gürültü giderimini sağlarken, SGS için gerekli olan çeşitliliğin azalmasıdır. Hem BBA' nın hem de bant seçiminin uygulanması, az sayıda etiketli veri olduğunda başarıyı artırmasına rağmen, fazla sayıda etiketli veri olduğunda başarıyı düşürmesinin nedeni gürültü giderimi gerçekleştirirken bilgi kaybına da sebep olunmasıdır. Tablolar beraber değerlendirildiğin SGS' nin daha gürültülü ve daha az etiketli örnek sayısı ile DVM' ye göre daha başarılı çalıştığı gözlemlenmiştir. Ayrıca az sayıda örnekli veriyle YGÖ sayesinde, tüm etiketli veri kullanılarak eğitilen sistemlerle aynı başarımın yakalanabileceği, Tablo 3.4' te her sınıftan 50 etiketli örnek ile alınan birleştirilmiş sistem sonucu göstermiştir.

3.3.2 İkinci Yaklaşım Sonuçları

Yarı-güdümlü öğrenmede her sınıfa ait etiketli veri sayısı 5, 10, 15, 20, 30, 40, 50 olarak ilklendirilerek, toplamda sırasıyla 45, 90, 135, 180, 270, 360, 450 etiketli veri kullanılarak 3921 eğitim verisinin tamamının tekrar etiketlendirilmesi sağlanmıştır. Her sınıf için seçilen başlangıç etiketli veri sayısına göre eğitim verisinin YGÖ sonucu elde edilen doğru etiketleme başarımları sonucu Tablo 3.6' da görülmektedir. Yaklaşım 1' den daha başarılı YGÖ sonuçlarının çıkması, rastgele alınan 10 örneğin ortalamasına en yakın örnek yerine küme merkezine en yakın örneklerin alınmasıyla daha çok bilgi taşıyan örneklerin seçildiğini göstermektedir.

Tablo 3.6 Farklı örnek sayıları için k-ortalamlar ile YGÖ başarımı sonuçları (%)

Örnek Sayısı	YGÖ Başarımı (%)
5x9	69.65
10x9	74.03
15x9	78.09
20x9	80.43
30x9	81.58
40x9	83.26
50x9	85.07

Tablo 3.7' de 5, 10, 15, 20, 30, 40, 50 etiketli örnek sayısına göre DVM, SGS ve birleştirilmiş sistem başarımları görülmektedir. Her sınıftan alınan 5 etiketli örnek ile alınan kombine sistem başarımları %76.50 olarak görülmektedir. Küme merkezlerine en yakın eğitim örneklerinin, küme içinde rastgele seçilen örneklerden YGÖ ve sınıflama açısından daha fazla bilgi taşıdığını Tablo 3.1 ve Tablo 3.6, Tablo 3.2 ve Tablo 3.7 çiftlerini karşılaştırarak görebiliriz. Ayrıca Tablo 3.7' de bulunan son sütunda DVM ve SGS' nin daha başarılı bir şekilde birleştirilebildiğinde alınabilecek maksimum başarımlar ortaya konulmuştur.

Tablo 3.7 K-ortalamlar kümeleme ile farklı örnek sayıları için sınıflama başarımı sonuçları (%)

Örnek Sayısı	DVM	SGS	Birleştirilmiş Sistem (%)	DVM-SGS Olası Maksimum Başarım (%)
5x9	73.54	76.34	76.50	78.78
10x9	74.34	76.83	77.11	83.04
15x9	77.67	79.61	79.94	87.39
20x9	78.91	80.04	80.31	88.93
30x9	79.23	79.92	80.19	90.42
40x9	79.31	80.81	81.09	91.34
50x9	79.59	81.57	81.94	92.13

K-ortalamlar kümeleme yerine eksiltici kümelemenin kullanılmasıyla az etiketli örnek yani görece daha az sayıdaki kümenin kullanılmasıyla elde edilen YGÖ sonuçların eksiltici kümeleme ile alınan sonuçların k-ortalamlar kümeleme ile alınan sonuçlara oranla daha iyi olduğu Tablo 3.8’ de görülmektedir. Fakat ilklendirilecek örnek sayısı çok daha fazla olduğunda eksiltici kümelemenin başarımının düştüğü gözlemlenmiştir.

Tablo 3.8 Farklı örnek sayıları için eksiltici kümeleme ile YGÖ başarımı sonuçları (%)

Örnek Sayısı	YGÖ Başarımı (%)
5x9	70.31
50x9	85.64

K-ortalamlar yerine eksiltici-kümeleme ile yapılan çalışma alınan sınıflama başarımları Tablo 3.9’ da görülmektedir. Eksiltici kümeleme ile alınan sonuçlar YGÖ başarımı olarak bakıldığında k-ortalamlar kümeleme yönteminden daha yüksektir. Fakat nihai sistem başarımı yani test örneklerinin sınıflanması sonuçları açısından değerlendirildiğinde k-ortalamlar kümeleme yöntemi test başarımı yönünden öne çıkmaktadır.

Tablo 3.9 Eksiltici kümeleme ile farklı örnek sayıları için sınıflama başarımı sonuçları (%)

Örnek Sayısı	DVM	SGS	Birleştirilmiş Sistem (%)	DVM-SGS Olası Maksimum Başarım (%)
5x9	69.42	73.25	73.36	75.58
50x9	76.18	80.26	80.44	87.71

3.3.3 Üçüncü Yaklaşım Sonuçları

Kullanılan yöntemi, yaklaşım 1 ve yaklaşım 2’ den temel farkı eğitim kümesindeki sınıf bilgisini ilklendirmenin ilk aşamasında hiçbir şekilde kullanmamasıdır. İlk

iki yöntemde her sınıftan eşit sayıda etiketli veri alınabilmesi için yöntemlerin ilk aşamasında her sınıf ayrılarak eşit sayıda örnek seçimi gerçekleştirilmektedir. Fakat bu yöntemde etiketli veri ilklendirmesi aşamasında her sınıftan farklı sayıda etiketli örnek gelebilmektedir. Eğitim ve test kümesinde her sınıftan eşit sayıda örnek olmaması ve verinin dağılımından dolayı etiketli veri seçiminin bu şekilde seçilmesinin YGÖ başarımını artırdığı Tablo 3.10’ da gözlemlenmiştir.

Tablo 3.10 Farklı örnek sayıları için eksiltici kümeleme ile YGÖ başarımı sonuçları (%)

Örnek Sayısı	YGÖ Başarımı (%)
5x9=45	71.28
10x9=90	75.38
15x9=135	79.52
20x9=180	81.40
30x9=270	82.22
40x9=360	83.80
50x9=450	85.59

Yaklaşım 3 için sınıflama başarımı YGÖ başarımıyla doğru orantılı olarak diğer yöntemlere göre daha yüksektir. Sınıflama sonucunda %82.66 gibi bir başarımlar oranı yakalanmıştır. DVM ile yapılmış daha önceki çalışmalarda tüm eğitim kümesinin etiketli olarak kullanılmasıyla alınan %80.16 sınıflama başarımının toplamda 450 etiketli örnek ile sağlanmıştır. Yaklaşım 3’ ün daha önce bahsedilen 2 yöntemden daha yüksek bir başarımlar vermesinin temel sebebi hem eğitim hem de test kümelerinde Tablo 2.1’ den de görülebileceği gibi her sınıfa ait örnek sayısı farklıdır. Dolayısıyla her sınıftan eşit sayıda etiketli örnek seçmek yerine eğitim ve test örnek sayısı daha fazla olan sınıflardan daha fazla sayıda etiketli örnek seçmek veri dağılımına baktığımızda daha fazla kazanç sağlayacaktır. Ayrıca Tablo 3.11’ de bulunan son sütunda DVM ve SGS’ nin daha başarılı bir şekilde birleştirilebildiğinde alınabilecek maksimum başarımlar ortaya konulmuştur.

Tablo 3.11 Farklı örnek sayıları için sınıflama başarımı sonuçları (%)

Örnek Sayısı	DVM	SGS	Birleştirilmiş Sistem (%)	DVM-SGS Olası Maksimum Başarım (%)
5x9=45	74.56	75.18	75.37	78.41
10x9=90	76.31	80.87	80.98	85.53
15x9=135	78.95	81.04	81.18	89.00
20x9=180	79.23	81.16	81.55	89.48
30x9=270	79.41	81.25	81.66	89.54
40x9=360	79.47	81.41	81.79	90.20
50x9=450	80.16	82.42	82.66	90.96

3.3.4 Dördüncü Yaklaşım Sonuçları

Seyrek sınıflayıcı tabanlı bu yöntem daha önceki yöntemlerle karşılaştırıldığında diğer yöntemlere göre genel olarak daha başarılı olduğu Tablo 3.12’ de gösterilmiştir. Yine tabloda görüleceği üzere küme çekirdekleri yönteminde kullanılan küme sayısının artırılması az da olsa YGÖ başarımıyla birlikte çalışma zamanını da artırmaktadır. Ayrıca bu yöntem kullanılırken minimum küme sayısının en az sınıf sayısı kadar olmasına dikkat edilmelidir. Çalıştırma sayısı parametresinin artırılması küme çekirdekleri yönteminin güvenilirliğini artırmaktadır fakat çalışma süresi kabul edilebilir sınırların dışına çıkmaktadır.

Tablo 3.12 Farklı örnek ve küme sayıları için YGÖ başarımı sonuçları (%)

Örnek Sayısı	Küme Sayısı	Çalıştırma Sayısı	YGÖ Başarımı (%)
5x9	9	10	69.29
5x9	18	10	69.90
5x9	27	10	70.68
5x9	45	10	71.38
50x9	9	10	85.23
50x9	45	10	85.64

SGS tabanlı YGÖ yönteminin yukarı görülen tabloda YGÖ başarımlarının diğer yöntemlerden daha yüksek olduğu göze çarpmaktadır fakat Tablo 3.13 incelendiğinde test kümesinin sınıflama sonuçlarının yaklaşım 3’ ten daha başarısız olduğu göze çarpmaktadır. Tabloda göze çarpan bir başka durum, eşit etiketli örnek sayısı için daha fazla kümeye sahip denemelerde daha yüksek başarımlar gözlemlenmiştir fakat yine de yöntem 3’ ün başarımları yakalanamamıştır. Ayrıca Tablo 3.13’ te bulunan son sütunda DVM ve SGS’ nin daha başarılı bir şekilde birleştirilebildiğinde alınabilecek maksimum başarımlar ortaya konulmuştur.

Tablo 3.13 Farklı örnek sayıları için sınıflama başarımları sonuçları (%)

Örnek Sayısı	Küme Sayısı	Çalıştırma Sayısı	DVM	SGS	Birleştirilmiş Sistem (%)	DVM-SGS Olası Maksimum Başarım (%)
5x9	9	10	72.85	74.41	74.74	77.28
5x9	18	10	73.39	75.50	75.64	79.22
5x9	27	10	73.62	75.62	75.80	80.03
5x9	45	10	74.01	76.53	76.70	80.20
50x9	9	10	74.84	78.28	78.44	87.56
50x9	45	10	73.38	78.62	78.74	88.16

3.3.5 Beşinci Yaklaşım Sonuçları

Her kümeden tek bir örnek alınarak öğrenilen eğitim kümesinde YGÖ başarımında ilk aşamanın etiketlediği örnek sayısının belirli bir noktaya kadar artırılması Tablo 3.14’te görüleceği üzere yaklaşık %0.7 başarım artımını sağlamıştır. Bunun temel nedeni seyrek gösterimin kullandığı sözlüğün çeşitliliğinin artmasıdır. Fakat ilk aşamanın etiketlediği örnek sayısının daha da artırılması YGÖ başarımını düşürmektedir. Bu sebeple ilk aşamada kullanılan YGÖ yönteminin ikinci aşamada kullanılan yöntemle oranla gürültülü veriye daha az dayanıklı olmasıdır.

Tablo 3.14 YGÖ Yaklaşım-1 ile etiketlenmiş farklı başlangıç örnek sayıları için YGÖ başarımı sonuçları (%)

Örnek Sayısı	Küme Sayısı	Çalıştırma Sayısı	YGÖ-1 Başlangıç Örnek Sayısı	YGÖ Başarımı (%)
1x9	9	10	45	67.84
1x9	9	10	90	68.55

Bu yöntemle temelde amaçlanan her sınıftan tek etiketli örnek bulunduğunda sınıflama başarımının ne kadar yukarıya taşınabileceğidir. Diğer yöntemlerle karşılaştırılabilir örnek sayısı tablolarında şu an bulunmadığı için diğer yöntemlerle başarım açısından karşılaştırma yapmak pek mümkün değildir. Fakat yaklaşım 1’de her sınıftan 5 etiketli örnek ile yakalanan başarımın bu yöntemle her sınıftan tek etiketli örnek kullanılarak yakalanabildiği Tablo 3.2 ve Tablo 3.15 karşılaştırıldığında görülmektedir. Ayrıca aşağıda sunulan tabloda YGÖ’ nün ilk aşamasındaki örnek sayısının belirli bir noktaya kadar artırılmasıyla sınıflama başarımının arttığı da ortaya koyulmuştur. Tablo 3.15’ de bulunan son sütunda DVM ve SGS’ nin daha başarılı bir şekilde birleştirilebildiğinde alınabilecek maksimum başarım ortaya koyulmuştur.

Tablo 3.15 YGÖ Yaklaşım-1 ile etiketlenmiş farklı başlangıç örnek sayıları için sınıflama başarımı sonuçları (%)

Örnek Sayısı	Küme Sayısı	Çalıştırma Sayısı	YGÖ-1 Örnek Sayısı	DVM	SGS	Birleştirilmiş Sistem (%)	DVM-SGS Olası Maksimum Başarım (%)
1x9	9	10	45	67.16	68.00	68.37	70.34
1x9	9	10	90	67.72	69.32	69.50	71.26

3.4 Sonuç ve Öneriler

Veri etiketlemenin/yer-gerçekliği oluşturma zorluğu ve maliyeti diğer alanlarda olduğu gibi hiperspektral görüntülemenin de en önemli problemlerinden biridir. Yapılan çalışmada YGÖ ve farklı sınıflayıcıların birleşimi ile az sayıdaki etiketli veriyle yüksek sistem başarımları hedeflenmiştir. Gürültülü ve hatalı eğitim verisinde SGS’

nin gürültüye ve eksik veriye dayanıklılığından, gürültüsü giderilmiş ve görece doğru eğitim verisine sahip olunan durumlarda DVM' nin güçlü sınıflama özelliğinden faydalanılarak birleştirilmiş bir sistem oluşturulmuştur. SGS' nin genel olarak DVM' den, YGÖ' den elde edilen eğitim kümesiyle sınıflama yaptığında daha başarılı sonuçlar elde edilmiştir.

YGÖ ile az sayıda etiketli veriyle yapılan sınıflama sonuçları, eğitim verisindeki yanlış etiketlemenin test verisinin sınıflama başarısını çok fazla düşürmediğini göstermiştir. Seçilen her başlangıç etiketli veri sayısı seviyesinde YGÖ başarımının %2-3 oranında arttığı, bunun da toplam sistem başarımını %1-2 oranında artırdığı gözlemlenmiştir. YGÖ' nün etiketli veri seçim ve öğrenme aşamalarında yapılacak geliştirmeler ile güdümlü öğrenme başarımlarına daha düşük etiketli veri ile ulaşılması da mümkündür. Geliştirilen sistemde farklı özellikleriyle ön plana çıkan iki sınıflayıcının kullanılması sisteme farklı etiketli veri sayılarında olabildiğince yüksek başarımların yakalanmasını sağlamıştır.


Yarı-güdümlü öğrenme ve sınıflama yöntemleri uygulanmadan önce her örnek piksel k pencere boyutunda komşulukla değerlendirilir. Pencere boyutunda alınan örneklere gürültü giderimi için 3 boyutlu Gauss Fonksiyonu ($\sigma=1$) uygulanır. Bu şekilde hem penceredeki merkez pikselin etkisi artırılır hem de daha gürültüsüz bantları ağırlığı artırılır. Sistemin işleyişine dair genel akış Şekil 4.1’ de görülmektedir.

Önerilen yöntemde amaçlanan sınıflandırma sistemi temel olarak iki ana bölümden oluşmaktadır. İlk kısım olan yarı-güdümlü öğrenmede kendi kendini eğiten bir model benimsenmiştir ve temel amaç az sayıdaki etiketli veriyi daha başarılı bir model oluşturabilmek için kullanmaktır. İkinci aşama olan sınıflandırma bölümünde DVM, çekirdek tabanlı seyrek öğrenme ve derin öğrenme sistemine dayanan birleştirilmiş bir yapı oluşturularak gürbüz bir sınıflayıcı hedeflenmiştir.

4.1 Yarı-Güdümlü Öğrenme

Yarı-güdümlü öğrenmede temel amaç az sayıdaki etiketli veri ile çok sayıdaki etiketli veriden elde edilebilecek başarıyı elde edebilmek veya yakınsayabilmektir. Bunun sebebi etiketli verilerin elde edilmesinin diğer tüm uzaktan algılama uygulamalarında olduğu gibi hiperspektral görüntüler için de zorlu ve masraflı bir işlem olmasıdır.

Yarı-güdümlü öğrenme iki temel aşamadan oluşmaktadır. Bunlardan ilki etiketli verilerin seçimi; ikincisi ise yeni etiketlenecek verilerin hangi kurala göre seçileceğidir. Yukarıda incelenen önceki çalışmalarda yarı-güdümlü öğrenmenin ilk aşaması olan etiketli veri seçiminin daha sonraki sistem sınıflama başarısına etkisinin ne kadar büyük olduğu görülmüştür. Bu neden etiketli veri seçim adımına yoğunlaşarak genel sistem başarımlarını artırmaya yönelik 2 farklı yöntem öne sürülmüştür.



Şekil 4.1 Genel sistem yapısı

4.1.1 Birinci Yarı-Güdümlü Öğrenme Yaklaşımı (K-ortalamlar Kümeleme)

Bir önceki bölümde yapılan çalışmada ve k-ortalamlar yöntemini temel alarak yapılan diğer çalışmalarda temel problem k-ortalamlar yöntemi başlangıç merkezlerinin rastgele olarak atanmasıdır. Geliştirilen çalışmada her sınıfa ait etiketli veriler seçilirken ilk merkez o sınıfa ait tüm örnekler uzaklığı en küçük örnek ilk merkez olarak atanır.

Etiketli örnek sayısının yarısı tamamlanana kadar seçilen merkezlere en yakın örnekler seçilir. Bu şekilde tüm etiketli veriyi kapsayacak merkez atamaları yapılır. Etiketli örnek sayısının yarısı tamamlandığında ise daha önce etiketlenen tüm örnekler en uzak örnekler küme merkezi olarak atanır. Bu şekilde etiketli verilerin merkezden ve çevresinden kapsanması amaçlanmıştır. İlkendirme işleminin tamamlanmasının ardından standart k-ortalamlar kümeleme yöntemi çalıştırılır. Kümeleme işleminin tamamlanmasının ardından küme merkezlerine en yakın etiketli veriler, yarı güdümlü öğrenmenin etiketli verileri olarak atanır.

İkinci aşamada graf tabanlı artımsal bir model baz alınmıştır. Artımsal modelde her seferinde yeni bir etiketsiz veri etiketlenir ve bir sonraki adım için eğitim kümesine katılır. Graf üzerinde her seferinde hali hazırda bulunan etiketli eğitim

kümesindeki örneklerden herhangi birine en yakın olan test örneği seçilerek eğitim kümesine katılır. Güvenilirlik skoru en yüksek olan etiketsiz veri, yani etiketli ve etiketsiz olarak eşleştirilen graf düğümlerinden birnirine en yakın olan çiftteki etiketsiz düğüm etiketlenerek eğitim kümesine katılır. Bu işlem L1 uzaklık ölçesiyle en yakın komşuluk kuralı referans alınarak gerçekleştirilmiştir. YGÖ başarımı ilklendirmede kullanılan etiketli veri sayısı ile doğru orantılıdır. Etiketlenen veri sayısı ne kadar çoksa yer-gerçekliğine o derece yakın öğrenme sonuçları elde edilmiş olur.

4.1.2 İkinci Yarı-Güdümlü Öğrenme Yaklaşımı (Eksiltici Kümeleme)

K-ortalamlar yönteminin geliştirilmiş versiyonu, fazla sayıdaki etiketli veri seçimlerinde iyi çalışırken, az sayıdaki etiketli veri seçimlerinde yeterince başarılı olmadığı görülmüştür. Eksiltici kümeleme (subtractive clustering) ile ilklendirme yapılmasının düşük sayıdaki etiketli verilerde daha iyi çalıştığı gözlemlenmiştir. Eksiltici öğrenmenin temel olarak çalışma prensibi örnek sayısının en fazla olduğu daha doğru bir ifadeyle örneklerin en yoğun olduğu nokta küme merkezi olarak seçilerek belirlenen bir d yarı çapı içinde kalan örnekleri eksilterek ikinci en yoğun noktayı küme merkezi yaparak yine aynı şekilde eksiltme işlemini gerçekleştirir. Bu işleme hiçbir küme merkezine dahil olmayan örnek kalmayana kadar devam edilir. Daha sonra önceki yöntemdeki gibi küme merkezlerine en yakın örnekler etiketli örnek olarak atanır.

İkinci aşamada önceki yöntemle aynı şekilde graf tabanlı artımsal bir model baz alınmıştır. Artımsal modelde her seferinde yeni bir etiketsiz veri etiketlenir ve bir sonraki adım için eğitim kümesine katılır. Graf üzerinde her seferinde hali hazırda bulunan etiketli eğitim kümesindeki örneklerden herhangi birine en yakın olan test örneği seçilerek eğitim kümesine katılır. Güvenilirlik skoru en yüksek olan etiketsiz veri, yani etiketli ve etiketsiz olarak eşleştirilen graf düğümlerinden birnirine en yakın olan çiftteki etiketsiz düğüm etiketlenerek eğitim kümesine katılır. Bu işlem L1 uzaklık ölçeğiyle en yakın komşuluk kuralı referans alınarak gerçekleştirilmiştir. YGÖ başarımı ilklendirmede kullanılan etiketli veri sayısı ile doğru orantılıdır. Etiketlenen veri sayısı ne kadar çoksa yer-gerçekliğine o derece yakın öğrenme sonuçları elde edilmiş olur.

4.2 DVM ve Seyrek Öğrenmenin Birleştirilmesi ile Sınıflandırma

Sınıflandırma sisteminde iki farklı sınıflayıcının birleştirilmesi hedeflenmiştir. Bunlardan ilki hiperspektral görüntü sınıflandırma alanında sıklıkla kullanılan DVM'dir. Diğeri ise daha çok hiperspektral ayrıştırma için kullanılan seyrek gösterim sınıflayıcısıdır. DVM temelde iki sınıflı, doğrusal-olmayan bir sınıflayıcı


olmasına rağmen; çok sınıflı doğrusal-olmayan sınıflandırma, dışbükey optimizasyon ve yoğunluk tahmini problemlerini çözmek için de kullanılagelen eğitici bir makine öğrenmesi yöntemidir. SGS, elde bulunan bir eğitim kümesinin doğrusal kombinasyonu ile yeni gelen bir test örneğinin ifade edilebileceğini kabul eden eğitici bir makine öğrenmesi yöntemidir. Temelde her bir sınıf için yakınsama hatasının çoğalan toplamına bakarak test örneğinin sınıflandırılması işlemini gerçekleştirir.

YGÖ ile elde edilen eğitim kümesi çok sınıflı DVM ile radyal tabanlı fonksiyon (RBF) kullanılarak yüksek boyutlu uzaya taşınarak sınıflandırma gerçekleştirmiştir. İkili bir sınıflayıcı olan DVM çok sınıflı olarak kullanılırken “bir sınıfa karşı bir sınıf” stratejisi benimsenmiştir. Seyrek gösterim sınıflayıcısı, DVM gibi RBF uzayına taşınarak kullanılmıştır. Dolayısıyla kullanılan SGS, çekirdek (kernel) seyrek gösterim sınıflayıcısıdır. SGS sınıflandırması yapılırken eğitim pikseli (spektral imza) SGS sözlüğü için bir atom olarak kabul edilir. Atom, SGS sözlüğü oluşturulurken sözlüğü oluşturan her bir bileşene verilen isimdir. Daha sonra her sınıf için o sınıfa ait tüm pikseller alınarak bir alt sözlük oluşturulur ve her sınıf için gelen test pikseli için yakınsama hatası hesaplanır. En küçük yakınsama hatasına sahip sınıf test pikselinin sınıfı olarak kabul edilir. SGS yakınsaması hesaplanırken doğrusal kombinasyon vektörü olan w bulunurken L1 norm minimizasyon algoritmalarından olan Homotopy tekniği kullanılmıştır. Açıklayıcı görsel olarak verilen Şekil 3.1’ de eşitliğin sağ tarafında bulunan matris her sınıf için ayrı ayrı oluşturulan matristir. Yine eşitliğin sağ tarafında bulunan seyrek vektör, ağırlık vektörünü ifade etmektedir. Eşitliğin sol tarafındaki vektör ise yakınsama vektörüdür. Test pikseli ile yakınsama vektörünün farkından elde edilen hata için kullanılan eşik değeri olan λ parametresi $\lambda = 0.001$ olarak kullanılmıştır.

Sistem birleştirilmesi, kullanılan her iki sınıflayıcının test sonuçlarının karşılaştırılmasıyla elde edilir. Her iki sınıflayıcı, sınıflama sonucunda aynı sınıfı işaret ediyorsa ortak sınıf sistem sonucu olarak kabul edilir. Bunun dışında sınıflayıcılar farklı sınıfları işaret ediyorsa, iki sınıflayıcının güvenilirlik skoruna bakılır, güvenilirlik skoru %90’ının üzerinde olan sınıflayıcının tahmini birleştirilmiş sistem başarımı olarak ele alınır. Fakat iki sınıflayıcı farklı sınıfları işaret ediyorsa ve güvenilirlik değerleri eşik değerinin altındaysa, test örneği için her iki sınıflayıcıdan 3 en-iyi sonuca bakılır ve karar seviyesi kaynaşımı (decision level fusion) gerçekleştirilir. Bu noktada her iki sınıflayıcı için 3 en-iyi sınıf sonuçları için güvenilirlik skoruna bakılır. DVM için bu güvenilirlik skoru ikili DVM’ den çok sınıflı DVM’ ye geçerken elde edilen birleşik olasılık hesabıdır ve bu olasılık $[0,1]$ arasına normalize edilir. SGS’de ise güvenilirlik skoru (3.10) eşitliğince hesaplanır. Bu eşitlikte Hata, verilen bir test örneği için hesaplanan sınıf hatasını temsil etmektedir. Daha sonra o test örneği için tüm sınıflara ait güvenilirlik skoru $[0,1]$ arasına normalize edilir.

4.3 Derin Öğrenme, DVM ve Seyrek Öğrenmenin Birleştirilmesi ile Sınıflandırma

Geleneksel sinir ağlarında da olduğu gibi derin sınıflayıcılarda da gelen bir örneğin sınıflama sonucunda doğru sınıflanıyorsa sınıflayıcının bu örnek için verdiği olasılık yanlış sonuç verdiklerine oranla çok yüksek olmaktadır. Yani derin sınıflayıcı bir örnek için kararsız kaldığında genel olarak yanlış karar vermesi muhtemeldir. Bunun yanında yüksek olasılıklı tahminler yaptığı örnekler içinde doğru karar vermesi olasıdır. Buradan hareketle derin sınıflayıcının daha önceki bölümde tanımlanmış birleşik sınıflayıcıya entegrasyonu gerçekleştirilmiştir. Bu özelliklerinin yanı sıra derin öğrenmenin diğer sınıflayılardan daha güçlü bir sınıflayıcı olduğu genel kabul gören bir yargı olduğu için derin sınıflayıcı, birleşik sınıflama sisteminin temel elemanıdır. Yani derin sınıflayıcı sınıfladığı bir örneği %90 oranında bir sınıfa atıyorsa, bu örnek için sınıf bilgisi derin sınıflayıcının belirlediği sınıftır. Eğer daha düşük bir olasılık bildirilmişse, örneğin sınıf bilgisi için daha önceki bölümde yapılmış olan birleşik sınıflama süreci işletilir. Daha önce yapılmış olan birleşik sınıflama süreci aşağıdaki gibi gerçekleşmektedir. Genel sistem yapısı Şekil 4.2 ile gösterilmiştir.



Şekil 4.2 Genel sistem yapısı

Sınıflandırma sisteminde iki farklı sınıflayıcının birleştirilmesi hedeflenmiştir. Bunlardan ilki hiperspektral görüntü sınıflandırma alanında sıklıkla kullanılan DVM'dir. Diğeri ise daha çok hiperspektral ayrıştırma için kullanılan seyrek gösterim sınıflayıcısıdır. DVM temelde iki sınıflı, doğrusal-olmayan bir sınıflayıcı olmasına rağmen; çok sınıflı doğrusal-olmayan sınıflandırma, dışbükey optimizasyon ve yoğunluk tahmini problemlerini çözmek için de kullanılagelen eğitici bir makine öğrenmesi yöntemidir. SGS, elde bulunan bir eğitim kümesinin doğrusal kombinasyonu ile yeni gelen bir test örneğinin ifade edilebileceğini kabul eden eğitici bir makine öğrenmesi yöntemidir. Temelde her bir sınıf için yakınsama hatasının çoğalan toplamına bakarak test örneğinin sınıflandırılması işlemini gerçekleştirir.

YGÖ ile elde edilen eğitim kümesi çok sınıflı DVM ile radyal tabanlı fonksiyon (RBF) kullanılarak yüksek boyutlu uzaya taşınarak sınıflandırma gerçekleştirmiştir. İkili bir sınıflayıcı olan DVM çok sınıflı olarak kullanılırken “bir sınıfa karşı bir sınıf” stratejisi benimsenmiştir. Seyrek gösterim sınıflayıcısı, DVM gibi RBF uzayına taşınarak kullanılmıştır. Dolayısıyla kullanılan SGS, çekirdek (kernel) seyrek gösterim sınıflayıcısıdır. SGS sınıflandırması yapılırken eğitim pikseli (spektral imza) SGS sözlüğü için bir atom olarak kabul edilir. Atom, SGS sözlüğü oluşturulurken sözlüğü oluşturan her bir bileşene verilen isimdir. Daha sonra her sınıf için o sınıfa ait tüm pikseller alınarak bir alt sözlük oluşturulur ve her sınıf için gelen test pikseli için yakınsama hatası hesaplanır. En küçük yakınsama hatasına sahip sınıf test pikselinin sınıfı olarak kabul edilir. SGS yakınsaması hesaplanırken doğrusal kombinasyon vektörü olan w bulunurken L1 norm minimizasyon algoritmalarından olan Homotopy tekniği kullanılmıştır. Açıklayıcı görsel olarak verilen Şekil 3.1' de eşitliğin sağ tarafında bulunan matris her sınıf için ayrı ayrı oluşturulan matristir. Yine eşitliğin sağ tarafında bulunan seyrek vektör, ağırlık vektörünü ifade etmektedir. Eşitliğin sol tarafındaki vektör ise yakınsama vektörüdür. Test pikseli ile yakınsama vektörünün farkından elde edilen hata için kullanılan eşik değeri olan λ parametresi $\lambda = 0.001$ olarak kullanılmıştır.

Sistem birleştirilmesi, kullanılan her iki sınıflayıcının test sonuçlarının karşılaştırılmasıyla elde edilir. Her iki sınıflayıcı, sınıflama sonucunda aynı sınıfı işaret ediyorsa ortak sınıf sistem sonucu olarak kabul edilir. Bunun dışında sınıflayıcılar farklı sınıfları işaret ediyorsa, iki sınıflayıcının güvenilirlik skoruna bakılır, güvenilirlik skoru %90'nın üzerinde olan sınıflayıcının tahmini birleştirilmiş sistem başarımı olarak ele alınır. Fakat iki sınıflayıcı farklı sınıfları işaret ediyorsa ve güvenilirlik değerleri eşik değerinin altındaysa, test örneği için her iki sınıflayıcıdan 3 en-iyi sonuca bakılır ve karar seviyesi kaynaşımı (decision level fusion) gerçekleştirilir. Bu noktada her iki sınıflayıcı için 3 en-iyi sınıf sonuçları için güvenilirlik skoruna bakılır. DVM için bu güvenilirlik skoru ikili DVM' den çok sınıflı DVM' ye geçerken elde edilen

birleşik olasılık hesabıdır ve bu olasılık $[0,1]$ arasına normalize edilir. SGS'de ise güvenilirlik skoru (3.10) eşitliğince hesaplanır. Bu eşitlikte Hata, verilen bir test örneği için hesaplanan sınıf hatasını temsil etmektedir. Daha sonra o test örneği için tüm sınıflara ait güvenilirlik skoru $[0,1]$ arasına normalize edilir.

Yukarıda bahsedilen bir önceki bölümde çalışılan DVM ve ÇSGS sınıflayıcılarını bir araya getiren birleştirilmiş sınıflayıcıya ek olarak derin sınıflayıcı hali hazırda bulunan bu sisteme entegre edilmiştir. Derin sınıflayıcı olarak görüntü işleme için özelleşmiş derin ağlar olan Evrişimsel Sinir Ağları (Convolutional Neural Networks) kullanılmıştır. Uygulanan derin öğrenme [130] çalışmasında nesne tanıma için kullanılan modelin hyperspectral görüntüler için modifiye edilmesiyle oluşturulan yeni bir modelin kullanılmasıyla gerçekleştirilmiştir. Yapılan modifikasyon neticesinde orijinal modelde 256×256 boyutunda bir giriş görüntüsü isteyen model istenilen boyutta kare bir resmi giriş olarak alabilecek hale getirilmiştir. Ayrıca orijinal modelde tamamen bağlı (fully connected) katmanlar olan son iki katmanın çıkış sayıları 4096-4096 iken modifiye edilmiş model bu katmanlar küçültülerek 256-512 boyutlarına getirilmiştir. Bunun yapılmasındaki temel amaç ağın karmaşıklığının azaltılarak daha hızlı yakınsama yapılabilmesidir. Ayrıca eğitim kümesindeki etiketli veri sayısı yapılan çalışmadakinden çok daha az olduğu için bağlantı sayısının azaltılmasından ağın öğrenme gücünün etkilenmediği görülmüştür. Orijinal çalışmada 1000 sınıflı bir ağ eğitimi gerçekleştirilmişken kullanılan veri kümesinden dolayı 9 veya 16 sınıf vardır. Bu nedenle tamamen bağlı katmanlardan sonra gelen çıkış katmanı sınıf sayısı kadar düğüme sahiptir.

Ağ sırasıyla veri katmanı, arka arkaya gelen 5 evrişim (convolution) katmanı, bunları takip eden tamamen bağlı 2 katman ve çıkış katmanı olmak üzere 8 katmandan oluşmaktadır (veri katmanı hariç). Birinci evrişim katmanında filtre boyutu 5×5 olmak üzere 96 adet filtre oluşmaktadır. Bunu takip eden evrişim katmanında filtre boyutu yine 5×5 olarak 256 adet filtre üretilmektedir. Üçüncü evrişim katmanında 3×3 filtre boyutunda toplam 384 filtre elde edilmektedir. Dördüncü katmanda aynı şekilde 3×3 filtre boyutu ile 384 filtre öğrenilmektedir. Beşinci ve son evrişim katmanında 3×3 filtre boyutu olmak üzere toplam 256 adet filtre oluşturulmuştur. Altıncı ve yedinci katmanlar olan iç çarpım (inner product) katmanlarının çıkışlarının boyutları daha önce yukarıda bahsettiğimiz gibi sırasıyla 256 ve 512 olarak belirlenmiştir. Yine bir iç ürün katmanı olan çıkış katmanının çıkış sayısı sınıf sayısı olduğundan dolayı 9 veya 16'dır. Orijinal modelde atlayarak uygulanan filtreler çalışmamızda kayan pencere (sliding window) yöntemiyle uygulanmıştır. Bunun nedeni orijinal çalışmada nesne tanıma yapıldığından dolayı ve atlamalı olarak filtre uygulanmıştır. Çalışmamızda ise uzamsal ve spektral bilgilerin devamlılığı ve arka arkaya gelmesi bizim için önemli bir bilgi olduğu için kayan pencere şeklinde filtreler uygulanmıştır.

4.4 DVM ve Seyrek Öğrenmenin Etiket Puanlamasıyla Birleştirilmesi ile Sınıflandırma

Daha önceki bölümlerde görülen açık ve elde edilebilecek sonuçlar ışığında kernel sparse representation classifier(KSRC) ve support vector machine(SVM) sınıflayıcı sonuçlarının birleştirilmesi farklı yöntemler uygulanarak en iyi sonuca ulaşılmıştır. Bu SRC ve SVM sınıflayıcılarının birleştirilmesi aşamasına kadar tüm işlemler bölüm 4.2’de anlatıldığı gibi yine aynı şekilde uygulanır fakat son birleştirme aşamasında aşağıda anlatıldığı şekilde bir karar seviyesi birleştirme gerçekleştirilir.

Sistem birleştirmesi, kullanılan her iki sınıflayıcının test sonuçlarının karşılaştırılmasıyla elde edilir. Her iki sınıflayıcı, sınıflama sonucunda aynı sınıfı işaret ediyorsa ortak sınıf sistem sonucu olarak kabul edilir. Bunun dışında sınıflayıcılar farklı sınıfları işaret ediyorsa, daha önceki çalışmalardan farklı olarak her bir sınıf için sınıflayıcıdan alınan sonuca göre bir puan ataması gerçekleştirilir. Örnek üstünden açıklayacak olursak; 9 sınıf bulunan bir veri kümesinde bir örnek için ikinci sınıf etiketi ilk sırada atandıysa 9 puan almaktadır. Diğer sınıflayıcıda da ikinci sırada ise 8 puan almaktadır ve ikinci sınıf etiketinin toplam puanı 17 olmaktadır. Toplam puanlar üzerinden sınıfların değerlendirmesi yapılmaktadır. Eğer iki farklı sınıf etiketi eşit ve maksimum puana sahipse daha önceki şekilde iki farklı sınıflayıcının güvenilirlik skorunun ortalaması alınarak örneğe ait sınıf etiketi belirlenir. DVM için bu güvenilirlik skoru ikili DVM’den çok sınıflı DVM’ye geçerken elde edilen birleşik olasılık hesabıdır ve bu olasılık $[0,1]$ arasına normalize edilir. SGS’de ise güvenilirlik skoru (3.10) eşitliğince hesaplanır. Bu eşitlikte Hata, verilen bir test örneği için hesaplanan sınıf hatasını temsil etmektedir. Daha sonra o test örneği için tüm sınıflara ait güvenilirlik skoru $[0,1]$ arasına normalize edilir.


4.5 Tüm Verinin Graf Tabanlı Sınıflandırılması

Bu bölümde varolan yöntemleri GPU destekli kodlanması üzerine yoğunlaşmıştır. Yapılan çalışmayla hızlı sonuç almaya ve daha fazla deney sonucu almaya imkan sağlamıştır.

GPU sağladığı hesaplama gücü sayesinde daha önceden uygulanan graf tabanlı yarı-güdümlü öğrenme yönteminde farklı yöntemler uygulanmıştır. Bu sayede yarı-güdümlü öğrenmenin başarısı artırılarak, model tabanlı geleneksel sınıflama mantığındaki yöntemler uygulanmadan sonuç alınmıştır. Genel sistem akışı Şekil 4.3’te gösterildiği şekildedir.

Daha önceki çalışmalarda her bir örnek ister hiçbir uzamsal bilgi kullanılmadan kxk

pencere boyutu kullanılarak elde edilen örnek küpleri şeklinde kullanılmıştır. d adet banda sahip bir hiperspektral veride her bir alt piksel küpü kxkxd şeklinde alt küpler şeklinde ifade edilerek kullanılmaktaydı. Yapılan çalışmada bu alt küpler spektral düzlemde daha küçük parçacıklara ayrılmaktadır. Bu ayırma işlemi her bir parçacıkta 10 spektral bant olacak şekilde gerçekleştirilmiştir. 200 spektral banta sahip bir veri kümesinde 20 adet spektral alt parçacık bulunmaktadır. Alt parçacıkta bulunacak bant sayısı deneysel sonuçlar ışığında belirlenmiştir. Parçacıklarda bulunan bant grupları ardışık bantlardan oluşmamaktadır. 200 spektral banta sahip veride ilk spektral parçacık 1, 11, 21, 31, 41, 51, 61, 71, 81, 91, 101, 111, 121, 131, 141, 151, 161, 171, 181, 191 spektral bantlarında oluşmaktadır. Yapılan tüm deneysel sonuçlar bu parçacıklar üzerinde gerçekleştirilmiştir.



Şekil 4.3 Graf tabanlı genel sistem akışı

Daha önce yapılan çalışmalarda hesaplama maliyetinden dolayı etiketleme işlemi sadece eğitim kümesinin belirli bir miktarı üzerinde gerçekleştirilmiştir. Graf tabanlı etiketleme işleminin GPU ile gerçekleştirilmesinin ardından eğitim ve test kümesinin birleştirilerek tüm veri kümesinin graf üzerinde etiketlenmesine olanak sağlanmıştır.

Ayrıca artan hesaplama gücü ile yukarıda bahsedilen spektral parçacıkların ayrı ayrı graflar üzerinde etiketlenmesi ve bu etiketlerin karar seviyesinde birleştirilmesiyle daha başarılı sonuçlar elde edilmiştir.

4.6 Deneysel Sonuçlar

Deneysel sonuçlar bölümü 4 alt bölümden oluşmaktadır. Bunlardan ilki yöntem bölümünde “ DVM ve Seyrek Öğrenmenin Birleştirilmesi ile Sınıflandırma” başlıklılandırılan bölümdür. Bu bölümde anlatılan sınıflama sisteminin başarımının değerlendirilmesi için ROSIS Pavia Üniversitesi ve HYDICE DC Mall hiperspektral görüntüleri kullanılmıştır. Bunlardan ilki olan Pavia Üniversitesi hiperspektral görüntüsü 610x340 boyutlarında olup, 103 spektral bant içermektedir. Bu veride güdümlü sınıflama için 9 sınıfa ait etiketli 3921 eğitim pikseli ve 42776 test pikseli bulunmaktadır. İkinci görüntü olan DC Mall hiperspektral görüntüsü 1208x307 boyutlarında olup 191 spektral banttan oluşmaktadır. Bu görüntüde güdümlü öğrenme için 7 sınıfa ait toplam 8079 etiketli örnek bulunmaktadır.

İkinci alt bölüm ise “ Derin Öğrenme, DVM ve Seyrek Öğrenmenin Birleştirilmesi ile Sınıflandırma” bölümüdür. Bu bölümde hedeflenen sınıflama sisteminin başarımının değerlendirilmesi için ROSIS Pavia Üniversitesi, Aviris Salinas ve Aviris Indian Pines hiperspektral görüntüleri kullanılmıştır. İkinci görüntü olan Aviris Indian Pines hiperspektral görüntüsü 145x145 boyutlarında olup 200 spektral banttan oluşmaktadır. Bu görüntüde güdümlü öğrenme için 16 sınıfa ait toplam 10249 etiketli örnek bulunmaktadır. Bu veri kümesi hem 16 sınıflı hem de yaygın olarak kullanıldığı şekilde 9 sınıfla sonuçlar elde edilmiştir. Üçüncü veri kümesi olan Aviris Salinas hiperspektral görüntüsünde 512x217 boyutlarında olup 204 spektral banttan oluşmaktadır. Bu görüntüde güdümlü öğrenme için 16 sınıfa ait toplam 54129 etiketli örnek bulunmaktadır.

Üçüncü bölümde yukarıda anlatılan veri kümelerinden Pavia Üniversite verisi ve DC Mall verisi kullanılmıştır. Dördüncü bölümde ise yine Pavia Üniversite verisinin yanında Indian Pines verisinin 9 ve 16 sınıflı halleri ayrı ayrı kullanılmıştır.

Aviris Indian Pines ve Salinas veri kümeleri için yer gerçekliğinde eğitim ve test için kullanılması gereken kümeler ayrı ayrı belirtilmediği için her için veri kümesinde her sınıfın %25’ i eğitim kümesi geriye kalan %75 test kümesi olarak kabul edilmiştir. Eğitim ve test örnekleri rastgele olarak belirlenmiştir.

Uygulanan yöntemde en yakın komşuluk için kullanılan uzaklık ölçütü L1 uzaklığıdır. Ayrıca DVM’ ler Radial Basis Function (Radyal Tabanlı Fonksiyon) ve cost(ceza)

parametresi olarak 1000 kullanılmıştır. DVM gibi ÇSGS’de de Radial Basis Function (Radyal Tabanlı Fonksiyon) uzayı ve NNQP seyrek kodlama kullanılmıştır. SGS için lambda değeri 0.001 olarak belirlenmiştir.

4.6.1 DVM ve Seyrek Öğrenmenin Birleştirilmesi ile Sınıflandırma Sonuçları

4.6.1.1 Birinci Yarı-Güdümlü Öğrenme Yaklaşımı (K-ortalamlar Kümeleme)

HYDICE DC Mall verisi ile yapılan deneyler sonucunda alınan yarı güdümlü öğrenme, DVM, çekirdek seyrek gösterim sınıflayıcısı ve birleştirilmiş sistem sonuçları Tablo 4.1’de görülmektedir.

Tablo 4.1 K-ortalamlar kümeleme ile alınan YGÖ, DVM, ÇSGS ve birleştirilmiş sistem başarımları sonuçları (DC Mall Hiperspektral Sahnesi) (%)

				Sınıflayıcı			
				SSL	SVM	KSRC	Kombine Sistem
Pencere Büyüklüğü	1x1	Etiketli Örnek Sayısı	5	94.65	97.29	97.75	97.86
			10	98.27	98.05	98.61	98.64
			15	98.99	98.23	99.08	99.13
			20	99.38	98.74	99.03	99.21
			30	99.72	98.84	99.59	99.63
			50	99.83	98.93	99.70	99.75
	3x3	Etiketli Örnek Sayısı	5	98.41	96.37	97.07	97.32
			10	99.57	99.71	99.45	99.89
			15	99.57	99.74	99.37	99.86
			20	99.94	99.94	99.75	99.94
			30	100	99.94	99.77	99.94
			50	100	99.94	99.77	99.94
	5x5	Etiketli Örnek Sayısı	5	98.70	96.95	97.03	97.47
			10	100	99.66	99.30	99.74
			15	100	99.66	99.30	99.74
			20	100	99.97	99.95	99.97
			30	100	99.97	99.95	99.97
			50	100	99.97	99.95	99.97

Deneyler farklı büyüklükte uzamsal bilginin kullanımının sistem başarımına etkisini görmek amacıyla 1, 3, 5 pencere boyutunda görüntüler alınarak gerçekleştirilmiştir. DC Mall verisinde eğitim ve test yer-gerçekleri ayrılmadığı için her sınıftan varsa 300 örnek yoksa bulunan örnek sayısı kadar örnek eğitim olarak alınarak, bu örnekler graf tabanlı yarı güdümlü öğrenme yöntemiyle etiketlenmiştir. Geri kalan örnekler test olarak DVM ve ÇSGS ile sınıflandırılmıştır. Başlangıçtaki etiketli örnek sayılarının sistem başarımına etkisinin incelenmesi amacıyla deneyler her sınıftan 5, 10, 15,

20, 30 ve 50 etiketli örneklerle gerçekleştirilmiştir. Bu veri kümesi için 3x3 ve 5x5 pencere boyutlarıyla alınan uzamsal bilginin en iyi sonuçları verdiği gözlemlenmiştir. Karşılaştırma açısından GRSL 2015’ de yayınlanan [153] çalışmasında aynı veri kümesi için alınan sonuçlar Tablo 4.1 ile karşılaştırıldığında geliştirilen sistemin daha başarılı olduğu görülmektedir.

Tablo 4.2 FKT tabanlı yapılan çalışma [153] ile alınan başarımların sonuçları (DC Mall Hiperspektral Sahnesi) (%)

		FKT	KFKT gauss	KFKT laplacian	KFKT cauchy	KFKTlog
Etiketli Örnek Sayısı	5	79.72	96.18	97.95	88.01	85.65
	10	91.50	96.89	96.51	93.92	88.25
	15	97.65	97.37	98.79	86.87	92.95
	20	94.85	98.25	96.48	91.69	97.32
	30	96.05	99.24	99.33	96.70	97.89
	50	99.07	99.90	99.85	97.15	97.47

Çekirdek tabanlı Fukunaga-Kontz Dönüşümü yapılan çalışmada Laplace dönüşümü ile en iyi sonuçlar alınmıştır. Her sınıftan 5 etiketli örneklerle alınan sonuçlar dışında bütün etiketli örnek sayılarında geliştirilen sistem 3x3 pencere boyutu için daha iyidir. Daha başarısız olduğu örnek sayısında %0.63 daha geride kalmıştır. Diğer çekirdek dönüşümleri ile alınan FKT tabanlı sonuçların hepsinden daha başarılı sonuçlar vermektedir.

Rosis Pavia Üniversitesi verisi ile yapılan deneyler sonucunda alınan yarı güdümlü öğrenme, DVM, çekirdek seyrek gösterim sınıflayıcısı ve birleştirilmiş sistem sonuçları Tablo 4.3’ te görülmektedir. Deneyler farklı büyüklükte uzamsal bilginin kullanımının sistem başarımına etkisini görmek amacıyla 1, 3, 5 pencere boyutunda görüntüler alınarak gerçekleştirilmiştir. Pavia Üniversitesi verisinde eğitim ve test yer-gerçekleri ayrı ayrı verilmiştir. Eğitim örnekleri graf tabanlı yarı güdümlü öğrenme yöntemiyle etiketlenmiştir. 42776 adet olan test örnekleri DVM ve ÇSGS ile sınıflandırılmıştır. Başlangıçtaki etiketli örnek sayılarının sistem başarımına etkisinin incelenmesi amacıyla deneyler her sınıftan 5, 10, 15, 20, 30 ve 50 etiketli örneklerle gerçekleştirilmiştir. Bu veri kümesi için 3x3 pencere boyutuyla alınan uzamsal bilginin en iyi sonucu verdiği gözlemlenmiştir. Karşılaştırma açısından GRSL 2015’ de yayınlanan [154] çalışmasında aynı veri kümesi için alınan sonuçlar Tablo 4.3 ile karşılaştırıldığında geliştirilen sistemin daha başarılı olduğu görülmektedir.

Yapılan çalışmaya benzer şekilde yarı-güdümlü öğrenme aşamasını gerçekleştiren [154] çalışması komşuluk tabanlı graf-öğrenmesi gerçekleştirmektedir. Ayrıca yarı-güdümlü sinir ağı (Semi-Supervised Neural Network (SSNN)) ile sınıflandırma

Tablo 4.3 K-ortalamlar kümeleme ile alınan YGÖ, DVM, ÇSGS ve birleştirilmiş sistem başarımları sonuçları (Pavia Üniversitesi Hiperpektral Sahnesi) (%)

Pencere Büyüklüğü	Sınıflayıcı						
				SSL	SVM	KSRC	Kombine Sistem
	1x1	Etiketli Örnek Sayısı	5	66.33	69.67	69.32	72.48
			10	66.56	73.08	70.79	75.19
			15	69.54	76.00	68.06	76.99
			20	72.12	75.80	71.26	78.10
			30	74.70	74.87	68.87	77.56
			50	74.85	74.68	68.70	77.81
	3x3	Etiketli Örnek Sayısı	5	76.23	76.11	76.45	77.87
			10	76.46	76.38	77.44	78.78
15			82.09	80.34	80.13	82.56	
20			81.96	81.02	81.31	83.12	
30			87.29	81.03	78.78	84.12	
50			90.20	80.38	75.84	84.09	
5x5	Etiketli Örnek Sayısı	5	82.04	67.74	56.88	72.17	
		10	87.32	73.54	64.53	76.39	
		15	89.44	81.49	75.91	82.60	
		20	89.18	80.04	73.72	82.36	
		30	94.18	82.39	75.31	84.98	
		50	97.04	83.75	75.55	86.18	

yapılmıştır. Bir önceki çalışmadaki gibi çekirdek tabanlı sınıflama yapıldığında en başarılı sonuçların Laplace fonksiyonu ile alındığı yapılan çalışmada gözlemlenmiştir. Bu çalışmada alınan sonuçlar Tablo 4.4’ de listelenmiştir. Eşit sayıdaki etiketli örnekler için değerlendirildiğinde geliştirilen sistemin (3x3 pencere boyutu) bütün etiketli örnek sayıları için daha başarılı çalıştığı fark edilmektedir.

Tablo 4.4 SSNN tabanlı yapılan çalışma [154] ile alınan başarımları sonuçları (Pavia Üniversitesi Hiperpektral Sahnesi) (%)

	Etiketli Örnek Sayısı			
	5	10	15	30
SSN	71.8±14.0	74.1±6.25	76.2±3.99	78.6±2.32
TSSNN	73.2±2.79	75.3±2.09	76.3±5.24	78.4±1.46
LapSSNN	72.7±2.82	74.1±1.35	74.9±4.07	75.8±1.28
TSSNN+DrLIM	72.7±5.01	75.3±2.48	76.2±2.40	78.6±1.96
LapSSNN+DrLIM	72.6±3.26	74.4±1.94	75.4±2.90	76.4±1.76
TSSNN+NGL	72.5±3.84	75.3±1.23	77.0±3.08	79.2±2.38
LapSSNN+NGL	76.8±1.45	77.8±1.84	79.5±2.48	80.3±0.87
TSSNN+MNGL	76.4±4.65	77.8±3.15	78.7±6.62	78.7±1.02
LapSSNN+MNGL	73.6±5.01	74.9±1.38	76.3±3.33	79.0±4.15

Tablo 4.5 Eksiltici kümeleme ile alınan YGÖ, DVM, ÇSGS ve birleştirilmiş sistem başarımları sonuçları (DC Mall Hiperspektral Sahnesi) (%)

				Sınıflayıcı			
				SSL	SVM	KSRC	Kombine Sistem
Pencere Büyüklüğü	1x1	Etiketli Örnek Sayısı	5	97.11	96.74	98.62	98.69
			10	98.41	98.08	99.14	99.24
			15	98.41	98.08	99.13	99.23
			20	99.20	98.86	99.50	99.56
			30	99.32	98.85	99.48	99.55
			50	99.32	98.83	99.48	99.55
	3x3	Etiketli Örnek Sayısı	5	95.08	99.72	99.53	99.85
			10	96.96	99.76	99.52	99.90
			15	99.71	99.81	99.45	99.90
			20	100	99.94	99.77	99.94
			30	100	99.94	99.77	99.94
			50	100	99.94	99.77	99.94
	5x5	Etiketli Örnek Sayısı	5	97.11	99.65	99.29	99.65
			10	100	99.66	99.30	99.74
			15	100	99.66	99.30	99.74
			20	100	99.97	99.95	99.97
			30	100	99.97	99.95	99.97
			50	100	99.97	99.95	99.97

4.6.1.2 Eksiltici Yarı-Güdümlü Öğrenme Yaklaşımı (Eksiltici Kümeleme)

HYDICE DC Mall verisi ile yapılan deneyler sonucunda alınan yarı güdümlü öğrenme, DVM, çekirdek seyrek gösterim sınıflayıcısı ve birleştirilmiş sistem sonuçları Tablo 4.5 ile görülmektedir. Deneyler farklı büyüklükte uzamsal bilginin kullanımının sistem başarımına etkisini görmek amacıyla 1, 3, 5 pencere boyutunda görüntüler alınarak gerçekleştirilmiştir. DC Mall verisinde eğitim ve test yer-gerçekleri ayrıldığı için her sınıftan varsa 300 örnek yoksa bulunan örnek sayısı kadar örnek eğitim olarak alınarak, bu örnekler graf tabanlı yarı güdümlü öğrenme yöntemiyle etiketlenmiştir. Geri kalan örnekler test olarak DVM ve ÇSGS ile sınıflandırılmıştır. Başlangıçtaki etiketli örnek sayılarının sistem başarımına etkisinin incelenmesi amacıyla deneyler her sınıftan 5, 10, 15, 20, 30 ve 50 etiketli örneklerle gerçekleştirilmiştir. Bu veri kümesi için 3x3 ve 5x5 pencere boyutlarıyla alınan uzamsal bilginin en iyi sonuçları verdiği gözlemlenmiştir. Karşılaştırma açısından GRSL 2015' de yayınlanan [153] çalışmasında aynı veri kümesi için alınan sonuçlar Tablo 4.5 ile karşılaştırıldığında geliştirilen sistemin daha başarılı olduğu görülmektedir.

Çekirdek tabanlı Fukunaga-Kontz Dönüşümü yapılan çalışmada Laplace dönüşümü ile en iyi sonuçlar alınmıştır. Tüm pencere boyutlarında alınan tüm sonuçlar için

Tablo 4.6 FKT tabanlı yapılan çalışma [153] ile alınan başarımlar sonuçları (DC Mall Hiperspektral Sahnesi) (%)

		FKT	KFKT gauss	KFKT laplacian	KFKT cauchy	KFKTlog
Etiketli Örnek Sayısı	5	79.72	96.18	97.95	88.01	85.65
	10	91.50	96.89	96.51	93.92	88.25
	15	97.65	97.37	98.79	86.87	92.95
	20	94.85	98.25	96.48	91.69	97.32
	30	96.05	99.24	99.33	96.70	97.89
	50	99.07	99.90	99.85	97.15	97.47

geliştirilen yöntemin FKT tabanlı yöntemden daha başarılı olduğu gözlemlenmiştir.

Rosis Pavia Üniversitesi verisi ile yapılan deneyler sonucunda alınan yarı güdümlü öğrenme, DVM, çekirdek seyrek gösterim sınıflayıcısı ve birleştirilmiş sistem sonuçları Tablo 4.7’ de görülmektedir. Deneyler farklı büyüklükte uzamsal bilginin kullanımının sistem başarımına etkisini görmek amacıyla 1, 3, 5 pencere boyutunda görüntüler alınarak gerçekleştirilmiştir. Pavia Üniversitesi verisinde eğitim ve test yer-gerçekleri ayrı ayrı verilmiştir. Eğitim örnekleri graf tabanlı yarı güdümlü öğrenme yöntemiyle etiketlenmiştir. 42776 adet olan test örnekleri DVM ve ÇSGS ile sınıflandırılmıştır. Başlangıçtaki etiketli örnek sayılarının sistem başarımına etkisinin incelenmesi amacıyla deneyler her sınıftan 5, 10, 15, 20, 30 ve 50 etiketli örneklerle gerçekleştirilmiştir. Bu veri kümesi için 3x3 pencere boyutuyla alınan uzamsal bilginin en iyi sonucu verdiği gözlemlenmiştir. Karşılaştırma açısından GRSL 2015’ de yayınlanan [154] çalışmasında aynı veri kümesi için alınan sonuçlar Tablo 4.7 ile karşılaştırıldığında geliştirilen sistemin daha başarılı olduğu görülmektedir.

Yapılan çalışmaya benzer şekilde yarı-güdümlü öğrenme aşamasını gerçekleştiren [154] çalışması komşuluk tabanlı graf-öğrenmesi gerçekleştirmektedir. Ayrıca yarı-güdümlü sinir ağı (Semi-Supervised Neural Network (SSNN)) ile sınıflandırma yapılmıştır. Bir önceki çalışmadaki gibi çekirdek tabanlı sınıflama yapıldığında en başarılı sonuçların Laplace fonksiyonu ile alındığı yapılan çalışmada gözlemlenmiştir. Bu çalışmada alınan sonuçlar Tablo 4.8’ de listelenmiştir. Eşit sayıdaki etiketli örnekler için değerlendirildiğin geliştirilen sistemin (3x3 pencere boyutu) bütün etiketli örnek sayıları için daha başarılı çalıştığı fark edilmektedir.

Geliştirilen her iki yöntemin yukarıdaki tablolar değerlendirildiğinde karşılaştırılan çalışmalardan daha başarılı olduğu gözlemlenmiştir. Düşük etiketli örnek sayıları için eksiltici kümeleme ile geliştirilen yöntemin daha yüksek başarımlar sağladığı görülmüştür. 5x5 komşuluk için çeşitlilik çok fazla arttığı için düşük etiketli örnek sayıları için başarımın düşmüştür.

Tablo 4.7 Eksiltici kümeleme ile alınan YGÖ, DVM, ÇSGS ve birleştirilmiş sistem başarımları sonuçları (Pavia Üniversitesi Hiperpektral Sahnesi) (%)

Pencere Büyüklüğü	Sınıflayıcı						
				SSL	SVM	KSRC	Kombine Sistem
	1x1	Etiketli Örnek Sayısı	5	71.25	73.62	77.65	79.00
			10	75.95	73.35	80.02	80.15
			15	77.81	70.59	78.18	80.75
			20	78.19	76.71	80.53	82.44
			30	78.80	72.31	78.62	82.05
	50	79.67	69.48	75.65	79.32		
	3x3	Etiketli Örnek Sayısı	5	79.80	81.52	82.90	83.47
			10	82.42	82.34	83.19	84.08
15			83.21	82.58	83.48	84.51	
20			84.85	82.05	82.57	84.77	
30			85.41	82.03	82.79	84.64	
50	86.20	83.33	82.52	85.43			
5x5	Etiketli Örnek Sayısı	5	70.74	68.63	65.70	70.19	
		10	75.23	71.84	70.04	74.13	
		15	82.73	78.27	75.77	80.68	
		20	83.19	77.78	75.44	80.47	
		30	82.73	78.09	77.18	82.16	
50	88.65	81.24	78.61	84.47			

Tablo 4.8 SSNN tabanlı yapılan çalışma [154] ile alınan başarımları sonuçları (Pavia Üniversitesi Hiperpektral Sahnesi) (%)

	Etiketli Örnek Sayısı			
	5	10	15	30
SSN	71.8±14.0	74.1±6.25	76.2±3.99	78.6±2.32
TSSNN	73.2±2.79	75.3±2.09	76.3±5.24	78.4±1.46
LapSSNN	72.7±2.82	74.1±1.35	74.9±4.07	75.8±1.28
TSSNN+DrLIM	72.7±5.01	75.3±2.48	76.2±2.40	78.6±1.96
LapSSNN+DrLIM	72.6±3.26	74.4±1.94	75.4±2.90	76.4±1.76
TSSNN+NGL	72.5±3.84	75.3±1.23	77.0±3.08	79.2±2.38
LapSSNN+NGL	76.8±1.45	77.8±1.84	79.5±2.48	80.3±0.87
TSSNN+MNGL	76.4±4.65	77.8±3.15	78.7±6.62	78.7±1.02
LapSSNN+MNGL	73.6±5.01	74.9±1.38	76.3±3.33	79.0±4.15

Sistem sonuç tabloları incelendiğinde pencere boyutu büyüdüğünde çeşitliliğin artmasında dolayı düşük etiketli örnek sayılarında sistem başarımının düştüğü görülmektedir. Fakat etiketli örnek sayısı arttıkça başarımın arttığı görülmüştür.

Küçük pencere boyutunda eksiltici kümeleme ile gerçekleştirilen çalışmanın k-ortalamları

kümeleme ile oluşturulan çalışmadan daha başarılı çalıştığı fakat etiketli örnek sayısı ve pencere boyutu büyüdüğünde k-ortalamlar kümeleme yöntemiyle ikklendirmenin başarısının daha yüksek olduğu görülmüştür.

4.6.2 Derin Öğrenme, DVM ve Seyrek Öğrenmenin Birleştirilmesi ile Sınıflandırma Sonuçları

4.6.2.1 Birinci Yarı-Güdümlü Öğrenme Yaklaşımı (K-ortalamlar Kümeleme)

Pavia Üniversitesi verisi ile yapılan deneyler sonucunda alınan yarı güdümlü öğrenme, DVM, çekirdek seyrek gösterim sınıflayıcısı, birleştirilmiş sistem sonuçları Tablo 4.9' da görülmektedir. Deneyler farklı büyüklükte uzamsal bilginin kullanımının sistem başarımına etkisini görmek amacıyla 1, 3, 5 pencere boyutunda görüntüler alınarak gerçekleştirilmiştir. Pavia Üniversite görüntüsünde eğitim ve test kümelerinin ayrı ayrı yer gerçekliği bulunduğundan dolayı 3921 örnek eğitim, 42776 örnek test olarak kullanılmıştır. Tabloda görülen SSL başarımlar oranları eğitim kümesi olan 3921 örnek için alınan yarı-güdümlü etiketleme başarımlardır. Geriye kalan 42776 örnek test olarak DVM, ÇSGS ve derin sınıflayıcı ile sınıflandırılmıştır. Başlangıçtaki etiketli örnek sayılarının sistem başarımına etkisinin incelenmesi amacıyla deneyler her sınıftan 5, 10, 15, 20, 30 ve 50 etiketli örneklerle gerçekleştirilmiştir. Bu veri kümesi için 3x3 ve 5x5 pencere boyutlarıyla alınan uzamsal bilginin en iyi sonuçları verdiği gözlemlenmiştir. Derin öğrenmenin eklenmesiyle oluşan yeni birleşik sınıflayıcı önceki bölümdeki birleşik sınıflayıcıdan daha başarılı olduğundan dolayı daha önce karşılaştırılan çalışmalardan yeni sistem de daha başarılıdır.

Uygulanan yöntemde en yakın komşuluk için kullanılan uzaklık ölçütü L1 uzaklığıdır. Ayrıca DVM' ler Radial Basis Function (Radyal Tabanlı Fonksiyon) ve cost(ceza) parametresi olarak 1000 kullanılmıştır. DVM gibi ÇSGS'de de Radial Basis Function (Radyal Tabanlı Fonksiyon) uzayı ve NNQP seyrek kodlama kullanılmıştır. SGS için lambda değeri 0.001 olarak belirlenmiştir. Derin öğrenme için 8 katmanlı bir yapı kullanılmıştır. Sinir ağı modelleri 60 epoch(devir) ile eğitilmiştir. Ayrıca derin öğrenme için eğitim kümesinin %10' u validasyon (doğrulama) için kullanılmıştır. Derin sınıflayıcı için öğrenme katsayısı (learning rate) 0.005 olarak belirlenmiştir.

Derin öğrenme ile alınan sonuçlar hem bir önceki bölümde birleştirilmiş sistemden hem de karşılaştırılan çalışmadan daha başarılı sonuçlar vermiştir. Bunun dışında derin öğrenmenin diğer sınıflayıcılarla birleştirilmesi ile saf derin öğrenme ile elde edilen sonuçlardan daha yüksek başarımlar elde edilmiştir.

Yapılan çalışmaya benzer şekilde yarı-güdümlü öğrenme aşamasını gerçekleştiren [154] çalışması komşuluk tabanlı graf-öğrenmesi gerçekleştirmektedir. Ayrıca

Tablo 4.9 K-ortalamlar kümeleme ile alınan YGÖ, DVM, ÇSGS, birleştirilmiş sistem, DNN ve DNN eklenmiş birleştirilmiş sistem başarımları sonuçları (Pavia Üniversite Hiperspektral Sahnesi) (%)

			Sınıflayıcı							
				SSL	SVM	KSRC	Kombine Sistem	LapSSNN + NGL	DNN	DNN ile Kombine
Pencere Büyüklüğü	1x1	Etiketli Örnek Sayısı	5	66.33	69.67	69.32	72.48	76.8±1.45	74.75	74.97
			10	66.56	73.08	70.79	75.19	77.8±1.84	80.25	79.54
			15	69.54	76.00	68.06	76.99	79.5±2.48	79.47	81.05
			20	72.12	75.80	71.26	78.10	N/A	79.82	82.80
			30	74.70	74.87	68.87	77.56	80.3±0.87	82.19	79.89
			50	74.85	74.68	68.70	77.81	N/A	81.97	82.10
	3x3	Etiketli Örnek Sayısı	5	76.23	76.11	76.45	77.87	76.8±1.45	81.42	83.36
			10	76.46	76.38	77.44	78.78	77.8±1.84	81.14	82.99
			15	82.09	80.34	80.13	82.56	79.5±2.48	86.15	86.67
			20	81.96	81.02	81.31	83.12	N/A	86.30	88.21
			30	87.29	81.03	78.78	84.12	80.3±0.87	87.80	89.42
			50	90.20	80.38	75.84	84.09	N/A	90.75	89.92
	5x5	Etiketli Örnek Sayısı	5	82.04	67.74	56.88	72.17	76.8±1.45	75.92	76.11
			10	87.32	73.54	64.53	76.39	77.8±1.84	82.93	84.10
			15	89.44	81.49	75.91	82.60	79.5±2.48	85.20	86.93
			20	89.18	80.04	73.72	82.36	N/A	84.89	86.12
			30	94.18	82.39	75.31	84.98	80.3±0.87	89.12	90.98
			50	97.04	83.75	75.55	86.18	N/A	90.28	91.58

Tablo 4.10 SSNN tabanlı yapılan çalışma [154] ile alınan başarımları sonuçları (Pavia Üniversitesi Hiperpektral Sahnesi) (%)

	Etiketli Örnek Sayısı			
	5	10	15	30
SSN	71.8±14.0	74.1±6.25	76.2±3.99	78.6±2.32
TSSNN	73.2±2.79	75.3±2.09	76.3±5.24	78.4±1.46
LapSSNN	72.7±2.82	74.1±1.35	74.9±4.07	75.8±1.28
TSSNN+DrLIM	72.7±5.01	75.3±2.48	76.2±2.40	78.6±1.96
LapSSNN+DrLIM	72.6±3.26	74.4±1.94	75.4±2.90	76.4±1.76
TSSNN+NGL	72.5±3.84	75.3±1.23	77.0±3.08	79.2±2.38
LapSSNN+NGL	76.8±1.45	77.8±1.84	79.5±2.48	80.3±0.87
TSSNN+MNGL	76.4±4.65	77.8±3.15	78.7±6.62	78.7±1.02
LapSSNN+MNGL	73.6±5.01	74.9±1.38	76.3±3.33	79.0±4.15

yarı-güdümlü sinir ağı (Semi-Supervised Neural Network (SSNN)) ile sınıflandırma yapılmıştır. Bir önceki çalışmadaki gibi çekirdek tabanlı sınıflama yapıldığında en başarılı sonuçların Laplace fonksiyonu ile alındığı yapılan çalışmada gözlemlenmiştir. Bu çalışmada alınan sonuçlar Tablo 4.10’ da listelenmiştir.

İkinci veri kümesi olarak kullanılan Aviris Indian Pines veri kümesinin 16 sınıf olan orijinal haliyle alınan sonuçlar Tablo 4.11’ de gösterilmektedir. Bazı sınıflar yaklaşık

Tablo 4.11 K-ortalamlar kümeleme ile alınan YGÖ, DVM, ÇSGS ve birleştirilmiş sistem başarımları sonuçları (Aviris Indian Pines Hiperspektral Sahnisi – 16 Sınıf) (%)

				Sınıflayıcı			
				SSL	SVM	KSRC	Kombine Sistem
Pencere Büyüklüğü	1x1	Etiketli Örnek Sayısı	5	63.72	61.89	62.49	64.16
			10	67.50	65.55	66.75	68.63
			15	68.78	66.50	68.38	70.41
			20	N/A	N/A	N/A	N/A
			30	N/A	N/A	N/A	N/A
			50	N/A	N/A	N/A	N/A
	3x3	Etiketli Örnek Sayısı	5	63.51	61.92	62.89	63.10
			10	69.73	67.16	69.28	70.94
			15	73.19	70.91	72.99	74.51
			20	N/A	N/A	N/A	N/A
			30	N/A	N/A	N/A	N/A
			50	N/A	N/A	N/A	N/A
	5x5	Etiketli Örnek Sayısı	5	70.37	69.26	69.79	72.12
			10	76.97	77.12	77.54	78.85
			15	78.19	78.03	78.39	79.67
			20	N/A	N/A	N/A	N/A
			30	N/A	N/A	N/A	N/A
			50	N/A	N/A	N/A	N/A

20-30 örneğe sahip olduğundan dolayı sınıflama sonuçları en fazla 15 etiketli sınıf için gerçekleştirilmiştir. Bu yöntem ile elde edilen en başarılı sonuçlar 5x5 pencere boyutu ile elde edilmiştir. Daha büyük pencere boyutları hesaplama maliyeti çok yüksek olduğu için test edilememiştir. Genel olarak pencere büyüklüğüyle artan bir başarımla göze çarpmaktadır.

Uygulanan yöntemde en yakın komşuluk için kullanılan uzaklık ölçütü L1 uzaklığıdır. Ayrıca DVM’ de linear(doğrusal) uzay ve cost(ceza) parametresi olarak 1000 kullanılmıştır. DVM gibi ÇSGS’de de linear(doğrusal) uzay ve NNQP seyrek kodlama kullanılmıştır. SGS için lambda değeri 0.001 olarak belirlenmiştir.

İkinci veri kümesi olarak kullanılan Aviris Indian Pines veri kümesinin en fazla örnek bulunduran 9 sınıflı haliyle alınan sonuçlar Tablo 4.12’ de gösterilmektedir. En fazla örnek içeren 9 sınıf test edildiğinde tüm etiketli örnek sayıları için sonuç elde edilmiştir. Bunun yanında 16 sınıfta olduğu gibi yine bu yöntemde en yüksek başarımla 5x5 pencere boyutu için elde edilmiştir. Ayrıca az örnek sayısına sahip sınıfların çıkarılmasıyla elde edilen alt veri kümesinde sonuçların daha yüksek olduğu gözlemlenmiştir. Geliştirilen sistemin her sınıftan fazla sayıda örnek olmasıyla daha

başarılı çalıştığı gözlemlenmiştir. Az örnek olan sınıfların sistem başarımına olumsuz etkisi bulunmaktadır.

Uygulanan yöntemde en yakın komşuluk için kullanılan uzaklık ölçütü L1 uzaklığıdır. Ayrıca DVM’ de linear(doğrusal) uzay ve cost(ceza) parametresi olarak 1000 kullanılmıştır. DVM gibi ÇSGS’de de linear(doğrusal) uzay ve NNQP seyrek kodlama kullanılmıştır. SGS için lambda değeri 0.001 olarak belirlenmiştir.

Üçüncü veri kümesi olarak kullanılan Aviris Salinas veri kümesine ait yarı-güdümlü öğrenme ve sınıflama sonuçları Tablo 4.13’ te gösterilmektedir. Daha önceki veri kümelerinde olduğu gibi k-ortalamlar ile ilklendirilen yarı-güdümlü öğrenmede en yüksek başarımlar 5x5 pencere boyutu için elde edilmiştir. Daha önceki veri kümelerinin sonuçlarıyla karşılaştırıldığında Pavia Üniversite veri kümesi gibi yüksek uzamsal çözünürlüğe sahip Salinas veri kümesinde de YGÖ başarımları yüksektir. Ayrıca derin öğrenme ile elde edilen sonuçlar yetersiz donanım ve süre kısıtından dolayı yeteri kadar eğitilmemiş bir ağdan alınan sonuçlardır, bu sonuçlar daha güçlü bir donanım ile geliştirilebilir. Fakat derin öğrenme optimum seviyede olmamasına rağmen DVM’ den daha başarılı sınıflama başarımları göstermektedir.

Uygulanan yöntemde en yakın komşuluk için kullanılan uzaklık ölçütü L1 uzaklığıdır. Ayrıca DVM’ de linear(doğrusal) uzay ve cost(ceza) parametresi olarak 1000 kullanılmıştır. Derin öğrenme için 8 katmanlı bir yapı kullanılmıştır. Süre kısıtından dolayı sinir ağı modelleri 18 epoch(devir) ile eğitilmiştir. Bu nedenle sınıflama modelleri olgunlaşmış modeller değildir. Ayrıca derin öğrenme için eğitim kümesinin %10’ u validasyon(doğrulama) için kullanılmıştır. Derin sınıflayıcı için öğrenme katsayısı (learning rate) 0.005 olarak belirlenmiştir.

4.6.2.2 Eksiltici Yarı-Güdümlü Öğrenme Yaklaşımı (Eksiltici Kümeleme)

Rosis Pavia Üniversitesi verisi ile yapılan deneyler sonucunda alınan yarı güdümlü öğrenme, DVM, çekirdek seyrek gösterim sınıflayıcısı ve birleştirilmiş sistem sonuçları Tablo 4.14’ te görülmektedir. Deneyler farklı büyüklükte uzamsal bilginin kullanımının sistem başarımına etkisini görmek amacıyla 1, 3, 5 pencere boyutunda görüntüler alınarak gerçekleştirilmiştir. Pavia Üniversitesi verisinde eğitim ve test yer-gerçekleri ayrı ayrı verilmiştir. Eğitim örnekleri graf tabanlı yarı güdümlü öğrenme yöntemiyle etiketlenmiştir. 42776 adet olan test örnekleri DVM ve ÇSGS ile sınıflandırılmıştır. Başlangıçtaki etiketli örnek sayılarının sistem başarımına etkisinin incelenmesi amacıyla deneyler her sınıftan 5, 10, 15, 20, 30 ve 50 etiketli örneklerle gerçekleştirilmiştir. Bu veri kümesi için 3x3 pencere boyutuyla alınan uzamsal bilginin en iyi sonucu verdiği gözlemlenmiştir. Karşılaştırma açısından GRSL 2015’

Tablo 4.12 K-ortalamalar kümeleme ile alınan YGÖ, DVM, ÇSGS ve birleştirilmiş sistem başarımları sonuçları (Avis Indian Pines Hiperspektral Sahnesi – 9 Sınıf) (%)

				Sınıflayıcı			
				SSL	SVM	KSRC	Kombine Sistem
Pencere Büyüklüğü	1x1	Etiketli Örnek Sayısı	5	67.87	65.97	67.24	68.12
			10	65.64	62.48	64.51	65.36
			15	68.13	64.74	67.96	69.41
			20	66.60	64.37	66.03	68.05
			30	73.07	69.47	72.53	73.71
			50	78.03	73.86	77.11	78.14
	3x3	Etiketli Örnek Sayısı	5	65.79	64.65	65.25	65.74
			10	70.21	67.97	68.89	70.62
			15	72.55	70.46	72.22	73.57
			20	74.24	72.07	74.29	74.96
			30	77.59	74.68	77.50	78.84
			50	81.92	78.35	81.47	82.83
	5x5	Etiketli Örnek Sayısı	5	77.33	75.93	76.93	77.81
			10	78.81	76.94	78.50	78.92
			15	79.15	77.22	78.47	80.09
			20	79.98	78.12	79.54	80.69
			30	80.34	79.41	80.07	81.46
			50	82.76	80.83	82.26	84.15

de yayınlanan [154] çalışmasında aynı veri kümesi için alınan sonuçlar Tablo 4.14 ile karşılaştırıldığında geliştirilen sistemin daha başarılı olduğu görülmektedir.

Uygulanan yöntemde en yakın komşuluk için kullanılan uzaklık ölçütü L1 uzaklığıdır. Ayrıca DVM' ler Radial Basis Function (Radyal Tabanlı Fonksiyon) ve cost(ceza) parametresi olarak 1000 kullanılmıştır. DVM gibi ÇSGS'de de Radial Basis Function (Radyal Tabanlı Fonksiyon) uzayı ve NNQP seyrek kodlama kullanılmıştır. SGS için lambda değeri 0.001 olarak belirlenmiştir. Derin öğrenme için 8 katmanlı bir yapı kullanılmıştır. Sinir ağı modelleri 60 epoch(devir) ile eğitilmiştir. Ayrıca derin öğrenme için eğitim kümesinin %10' u validasyon(doğrulama) için kullanılmıştır. Derin sınıflayıcı için öğrenme katsayısı (learning rate) 0.005 olarak belirlenmiştir.

Yapılan çalışmaya benzer şekilde yarı-güdümlü öğrenme aşamasını gerçekleştiren [154] çalışması komşuluk tabanlı graf-öğrenmesi gerçekleştirmektedir. Ayrıca yarı-güdümlü sinir ağı (Semi-Supervised Neural Network (SSNN)) ile sınıflandırma yapılmıştır. Bir önceki çalışmadaki gibi çekirdek tabanlı sınıflama yapıldığında en başarılı sonuçların Laplace fonksiyonu ile alındığı yapılan çalışmada gözlemlenmiş. Bu çalışmada alınan sonuçlar Tablo 4.15' de listelenmiştir. Eşit sayıdaki etiketli örnekler

Tablo 4.13 K-ortalamlar kümeleme ile alınan YGÖ, DVM, derin sınıflayıcı ve birleştirilmiş sistem başarımları sonuçları (Aviris Salinas Hiperspektral Sahnesi) (%)

				Sınıflayıcı			
				SSL	SVM	DNN	SVM ve DNN Birleşimi
Pencere Büyüklüğü	1x1	Etiketli Örnek Sayısı	5	89.90	91.10	91.72	91.92
			10	90.01	91.16	91.87	92.01
			15	90.12	91.23	92.06	92.19
			20	90.24	91.32	92.10	92.35
			30	90.39	91.35	92.05	92.42
			50	90.62	91.47	92.17	92.59
	3x3	Etiketli Örnek Sayısı	5	90.76	91.87	92.14	92.63
			10	90.78	91.92	92.29	93.79
			15	90.85	91.90	92.43	92.89
			20	90.89	92.02	92.56	92.98
			30	91.00	92.05	92.68	93.04
			50	91.18	92.28	92.71	93.01
	5x5	Etiketli Örnek Sayısı	5	93.89	93.05	93.52	93.76
			10	93.96	93.11	93.46	93.73
			15	93.99	93.07	93.63	93.89
			20	94.03	93.15	93.70	93.96
			30	94.12	93.23	93.69	94.03
			50	94.27	93.33	93.76	94.11

için değerlendirildiğin geliştirilen sistemin (3x3 pencere boyutu) bütün etiketli örnek sayıları için daha başarılı çalıştığı fark edilmektedir.

İkinci veri kümesi olarak kullanılan Aviris Indian Pines veri kümesinin 16 sınıf olan orijinal haliyle alınan sonuçlar Tablo 4.16’ da gösterilmektedir. Bazı sınıflar yaklaşık 20-30 örneğe sahip olduğundan dolayı sınıflama sonuçları en fazla 15 etiketli sınıf için gerçekleştirilmiştir. Bu yöntem ile elde edilen en başarılı sonuçlar 5-10 etiketli örnek için 1x1 pencere boyutu, 15 etiketli örnek için 3x3 pencere boyutu ile elde edilmiştir. Daha büyük pencere boyutları hesaplama maliyeti çok yüksek olduğu için test edilememiştir. Genel olarak pencere büyüklüğüyle azalan bir başarımlar göze çarpmaktadır. Bunun nedeni eksiltici kümelemenin örneklerin saf olmamasından olumsuz yönde etkilenmesidir. Sınıfların birbirine etkisi arttıkça başarımları genel olarak azalma eğilimindedir.

Uygulanan yöntemde en yakın komşuluk için kullanılan uzaklık ölçütü L1 uzaklığıdır. Ayrıca DVM’ de linear(doğrusal) uzay ve cost(ceza) parametresi olarak 1000 kullanılmıştır. DVM gibi ÇSGS’de de linear(doğrusal) uzay ve NNQP seyrek kodlama kullanılmıştır. SGS için lambda değeri 0.001 olarak belirlenmiştir.

Tablo 4.14 Eksiltici kümeleme ile alınan YGÖ, DVM, ÇSGS, birleştirilmiş sistem, DNN ve DNN eklenmiş birleştirilmiş sistem başarımları sonuçları (Pavia Üniversitesi Hiperpektral Sahnesi) (%)

			Sınıflayıcı							
				SSL	SVM	KSRC	Kombine Sistem	LapSSNN + NGL	DNN	DNN ile Kombine
Pencere Büyüklüğü	1x1	Etiketli Örnek Sayısı	5	71.25	73.62	77.65	79.00	76.8±1.45	78.42	80.36
			10	75.95	73.35	80.02	80.15	77.8±1.84	82.68	86.35
			15	77.81	70.59	78.18	80.75	79.5±2.48	80.52	83.82
			20	78.19	76.71	80.53	82.44	N/A	83.23	87.51
			30	78.80	72.31	78.62	82.05	80.3±0.87	81.03	84.49
			50	79.67	69.48	75.65	79.32	N/A	83.02	86.12
	3x3	Etiketli Örnek Sayısı	5	79.80	81.52	82.90	83.47	76.8±1.45	85.34	87.09
			10	82.42	82.34	83.19	84.08	77.8±1.84	86.95	88.18
			15	83.21	82.58	83.48	84.51	79.5±2.48	85.70	87.82
			20	84.85	82.05	82.57	84.77	N/A	86.00	89.22
			30	85.41	82.03	82.79	84.64	80.3±0.87	86.17	88.63
			50	86.20	83.33	82.52	85.43	N/A	86.99	89.89
	5x5	Etiketli Örnek Sayısı	5	70.74	68.63	65.70	70.19	76.8±1.45	73.96	74.46
			10	75.23	71.84	70.04	74.13	77.8±1.84	77.01	77.39
			15	82.73	78.27	75.77	80.68	79.5±2.48	84.14	84.49
			20	83.19	77.78	75.44	80.47	N/A	81.99	82.44
			30	82.73	78.09	77.18	82.16	80.3±0.87	81.11	82.28
			50	88.65	81.24	78.61	84.47	N/A	85.97	87.10

Tablo 4.15 SSNN tabanlı yapılan çalışma [154] ile alınan başarımları sonuçları (Pavia Üniversitesi Hiperpektral Sahnesi) (%)

	Etiketli Örnek Sayısı			
	5	10	15	30
SSN	71.8±14.0	74.1±6.25	76.2±3.99	78.6±2.32
TSSNN	73.2±2.79	75.3±2.09	76.3±5.24	78.4±1.46
LapSSNN	72.7±2.82	74.1±1.35	74.9±4.07	75.8±1.28
TSSNN+DrLIM	72.7±5.01	75.3±2.48	76.2±2.40	78.6±1.96
LapSSNN+DrLIM	72.6±3.26	74.4±1.94	75.4±2.90	76.4±1.76
TSSNN+NGL	72.5±3.84	75.3±1.23	77.0±3.08	79.2±2.38
LapSSNN+NGL	76.8±1.45	77.8±1.84	79.5±2.48	80.3±0.87
TSSNN+MNGL	76.4±4.65	77.8±3.15	78.7±6.62	78.7±1.02
LapSSNN+MNGL	73.6±5.01	74.9±1.38	76.3±3.33	79.0±4.15

İkinci veri kümesi olarak kullanılan Aviris Indian Pines veri kümesinin en fazla örnek bulunduran 9 sınıflı haliyle alınan sonuçlar Tablo 4.17’ de gösterilmektedir. En fazla örnek içeren 9 sınıf test edildiğinde tüm etiketli örnek sayıları için sonuç elde edilmiştir. Bunun yanında 16 sınıfta olduğu gibi yine bu yöntemde en yüksek başarımları 1x1 pencere boyutu için elde edilmiştir. Ayrıca az örnek sayısına sahip sınıfların çıkarılmasıyla elde edilen alt veri kümesinde sonuçların daha yüksek olduğu gözlemlenmiştir. Geliştirilen sistemin her sınıftan fazla sayıda örnek olmasıyla

Tablo 4.16 Eksiltici kümeleme ile alınan YGÖ, DVM, ÇSGS ve birleştirilmiş sistem başarımları sonuçları (Avisis Indian Pines Hiperspektral Sahnesi – 16 Sınıf) (%)

				Sınıflayıcı			
				SSL	SVM	KSRC	Kombine Sistem
Pencere Büyüklüğü	1x1	Etiketli Örnek Sayısı	5	55.57	54.03	54.57	56.13
			10	61.63	58.14	60.44	62.54
			15	65.20	61.15	64.36	66.39
			20	N/A	N/A	N/A	N/A
			30	N/A	N/A	N/A	N/A
			50	N/A	N/A	N/A	N/A
	3x3	Etiketli Örnek Sayısı	5	54.41	53.33	54.37	57.24
			10	58.61	57.00	58.40	60.31
			15	67.02	64.99	66.70	69.73
			20	N/A	N/A	N/A	N/A
			30	N/A	N/A	N/A	N/A
			50	N/A	N/A	N/A	N/A
	5x5	Etiketli Örnek Sayısı	5	45.87	46.61	47.38	48.12
			10	48.73	48.16	49.29	51.60
			15	50.13	52.27	51.98	52.64
			20	N/A	N/A	N/A	N/A
			30	N/A	N/A	N/A	N/A
			50	N/A	N/A	N/A	N/A

Tablo 4.17 Eksiltici kümeleme ile alınan YGÖ, DVM, ÇSGS ve birleştirilmiş sistem başarımları sonuçları (Avisis Indian Pines Hiperspektral Sahnesi – 9 Sınıf) (%)

				Sınıflayıcı			
				SSL	SVM	KSRC	Kombine Sistem
Pencere Büyüklüğü	1x1	Etiketli Örnek Sayısı	5	62.70	61.82	62.30	62.44
			10	67.89	65.32	67.08	69.34
			15	70.84	68.26	70.06	71.52
			20	72.33	69.21	71.61	72.97
			30	73.85	70.14	73.54	75.61
			50	77.16	72.82	76.53	78.92
	3x3	Etiketli Örnek Sayısı	5	48.93	48.17	48.41	49.73
			10	54.06	53.18	53.60	53.89
			15	55.62	54.66	55.26	57.46
			20	56.46	55.30	56.32	58.91
			30	57.33	55.35	56.92	58.95
			50	61.40	59.18	60.95	63.19
	5x5	Etiketli Örnek Sayısı	5	33.04	32.79	33.27	34.49
			10	35.33	35.26	35.89	37.11
			15	38.71	38.85	39.26	41.53
			20	39.58	39.47	39.95	42.64
			30	41.37	41.46	41.93	44.29
			50	43.91	44.08	44.51	45.57

daha başarılı çalıştığı gözlemlenmiştir. Az örnek olan sınıfların sistem başarımına olumsuz etkisi bulunmaktadır. Bunun yanında burada yukarıda bahsedilen örneklerin saflıklarından olumsuz etkilenme daha net bir şekilde gözlemlenmektedir. Pencere boyutu büyüdükçe yarı-güdümlü öğrenme başarımı ve sınıflama başarımı dikkat çekici bir şekilde azalmaktadır. Bunun diğer veri kümelerinde olmayıp bu veri kümesinde daha etkili olmasının sebebi Indian Pines veri kümesinin uzamsal çözünürlüğünün diğer veri kümelerine oranla çok düşük olmasıdır.

Tablo 4.18 Eksiltici kümeleme ile alınan YGÖ, DVM, derin sınıflayıcı ve birleştirilmiş sistem başarımı sonuçları (Aviris Salinas Hiperspektral Sahnesi) (%)

			Sınıflayıcı			
			SSL	SVM	DNN	SVM ve DNN Birleşimi
Pencere Büyüklüğü	1x1	Etiketli Örnek Sayısı	5	89.89	91.07	91.41
			10	89.95	91.11	91.46
			15	90.02	91.12	91.54
			20	90.06	91.14	91.65
			30	90.13	91.15	91.62
			50	90.26	91.23	91.78
	3x3	Etiketli Örnek Sayısı	5	90.81	91.98	92.39
			10	90.91	91.97	92.43
			15	91.01	92.13	92.74
			20	91.08	92.23	92.82
			30	91.20	92.32	92.91
			50	91.34	92.44	92.97
	5x5	Etiketli Örnek Sayısı	5	93.94	93.13	93.55
			10	93.99	93.18	93.61
			15	94.08	93.24	93.74
			20	94.11	93.31	93.71
			30	94.19	93.40	93.78
			50	94.31	93.49	93.84

Uygulanan yöntemde en yakın komşuluk için kullanılan uzaklık ölçütü L1 uzaklığıdır. Ayrıca DVM’ de linear(doğrusal) uzay ve cost(ceza) parametresi olarak 1000 kullanılmıştır. DVM gibi ÇSGS’de de linear(doğrusal) uzay ve NNQP seyrek kodlama kullanılmıştır. SGS için lambda değeri 0.001 olarak belirlenmiştir.

Üçüncü veri kümesi olarak kullanılan Aviris Salinas veri kümesine ait yarı-güdümlü öğrenme ve sınıflama sonuçları Tablo 4.18’ de gösterilmektedir. Daha önceki veri kümelerinde olduğu gibi eksiltici kümeleme ile ilklendirilen yarı-güdümlü öğrenmede en yüksek başarımlar 5x5 pencere boyutu için elde edilmiştir. Daha önceki veri kümelerinin sonuçlarıyla karşılaştırıldığında Pavia Üniversite veri kümesi gibi yüksek uzamsal çözünürlüğe sahip Salinas veri kümesinde de YGÖ başarımı yüksektir. Ayrıca

derin öğrenme ile elde edilen sonuçlar yetersiz donanım ve süre kısıtından dolayı yeteri kadar eğitilmemiş bir ağdan alınan sonuçlardır, bu sonuçlar daha güçlü bir donanım ile geliştirilebilir. Fakat derin öğrenme optimum seviyede olmamasına rağmen DVM' den daha başarılı sınıflama başarımı göstermektedir.

Uygulanan yöntemde en yakın komşuluk için kullanılan uzaklık ölçütü L1 uzaklığıdır. Ayrıca DVM' de linear(doğrusal) uzay ve cost(ceza) parametresi olarak 1000 kullanılmıştır. Derin öğrenme için 8 katmanlı bir yapı kullanılmıştır. Süre kısıtından dolayı sinir ağı modelleri 18 epoch(devir) ile eğitilmiştir. Bu nedenle sınıflama modelleri olgunlaşmış modeller değildir. Ayrıca derin öğrenme için eğitim kümesinin %10' u validasyon(doğrulama) için kullanılmıştır. Derin sınıflayıcı için öğrenme katsayısı (learning rate) 0.005 olarak belirlenmiştir.

Salinas veri kümesindeki örnekler diğer veri kümelerine oranla daha saf olduğu için pencere boyutu arttıkça sistem başarımı artmıştır. Örneklerin diğer veri kümelerine oranla daha saf olması, Salinas veri kümesinde tüm pencere boyutları için eksiltici kümeleme ile daha başarılı sonuçlar elde edilmesini sağlamıştır.

Geliştirilen her iki yöntemin yukarıdaki tablolar değerlendirildiğinde, karşılaştırılan çalışmalardan daha başarılı olduğu gözlemlenmiştir. Düşük etiketli örnek sayıları için eksiltici kümeleme ile geliştirilen yöntemin daha yüksek başarımlar sağladığı görülmüştür. 5x5 komşuluk için çeşitlilik çok fazla arttığı için düşük etiketli örnek sayıları için eksiltici kümelemede başarımlar düşmüştür.

Sistem sonuç tabloları incelendiğinde pencere boyutu büyüdüğünde çeşitliliğin artmasında dolayı düşük etiketli örnek sayılarında sistem başarımının düştüğü görülmektedir. Fakat etiketli örnek sayısı arttıkça başarımın arttığı görülmüştür.

Küçük pencere boyutunda eksiltici kümeleme ile gerçekleştirilen çalışmanın k-ortalamlar kümeleme ile oluşturulan çalışmadan daha başarılı çalıştığı fakat etiketli örnek sayısı ve pencere boyutu büyüdüğünde k-ortalamlar kümeleme yöntemiyle ilkendirilenin başarımının daha yüksek olduğu görülmüştür.

Farklı veri kümeleri için yapılan çalışmalar yöntemlerin başarılı olması için yüksek uzamsal çözünürlüğün bir gereklilik olduğu göstermektedir. Düşük uzamsal çözünürlükte yarı-güdümlü öğrenme başarımı ve buna bağlı olarak sınıflama başarımı çarpıcı bir şekilde düşmektedir.

Artan spektral çözünürlük daha fazla bilgi sağlamanın yanında, uzamsal olarak alınan pencerelerle beraber bir hesaplama problemini de beraberinde getirmektedir. Hem yarı güdümlü öğrenmeden ve DVM' den gelen düşük başarımlar hem de

veri sayısının fazlalığı ve spektral çözünürlüğün yüksekliği nedeniyle ortaya çıkan hesaplama maliyetinden dolayı IndianPines veri kümesi için derin öğrenme sonuçları oluşturulmamıştır.

4.6.3 DVM ve Seyrek Öğrenmenin Etiket Puanlamasıyla Birleştirilmesi ile Sınıflandırma

Pavia Üniversitesi ve DC Mall verisi ile yarı güdümlü öğrenme ile yapılan deneylerde eğitim kümesini etiketleme başarımları Tablo 4.19’ da gösterilmektedir. Tabloda hem k-ortalamlar yöntemi ile hem de eksiltici kümeleme ile alınan yarı güdümlü öğrenme başarımları sonuçları raporlanmıştır.

Tablo 4.19 K-ortalamlar ve eksiltici kümeleme ile alınan YGÖ eğitim kümesi başarımları sonuçları (DC Mall ve Pavia Üniversite Hiperspektral Sahnesi) (%)

				Kümeleyici			
				DC Mall		Pavia Üniversite	
				K-ortalamlar	Eksiltici	K-ortalamlar	Eksiltici
Pencere Büyüklüğü	1x1	Etiketli Örnek Sayısı	5	99.30	99.38	85.84	86.30
			15	99.34	99.50	85.76	87.40
			30	99.34	99.65	85.48	88.73
			50	99.38	99.69	85.19	90.13
	3x3	Etiketli Örnek Sayısı	5	99.65	99.73	95.49	95.79
			15	99.69	99.85	95.40	96.30
			30	99.77	99.88	95.43	96.97
			50	99.77	99.96	95.25	97.58
	5x5	Etiketli Örnek Sayısı	5	99.85	99.85	98.01	98.09
			15	99.85	99.96	97.99	98.24
			30	99.85	100	97.97	98.47
			50	99.92	100	98.01	98.85
	7x7	Etiketli Örnek Sayısı	5	99.96	99.96	99.02	99.03
			15	99.96	99.96	99.02	99.21
			30	99.96	99.96	99.07	99.24
			50	99.96	100	99.08	99.34
	9x9	Etiketli Örnek Sayısı	5	99.77	99.85	99.41	99.44
			15	99.77	99.88	99.42	99.52
			30	99.77	99.92	99.45	99.57
			50	99.77	99.96	99.48	99.57

1, 3, 5, 7 ve 9 pencere boyutları için alınan sonuçlarda pencere boyutu ve alınan etiketli örnek sayısı arttıkça başarımın arttığı görülmektedir. Ayrıca, eksiltici kümelemenin k-ortalamlar ile ilklendirmeden daha başarılı olduğu gözlemlenmiştir.

Sistem k-ortalamlar kümeleyicisi ile ilklendirildiğinde DC Mall verisi için alınan DVM, ÇSGS ve birleştirilmiş sistem başarımları sonuçları ve karşılaştırılan KFKT

tabanlı yöntemlerin sonuçları Tablo 4.20’ de bulunmaktadır. Birleştirilmiş sistem başarımı DVM ve ÇSGS ile alınan sonuçlardan daha başarılıdır. Fakat 50 etiketli örnek için karşılaştırılan Gaussian KFKT yönteminin daha yüksek sonuçlar verdiği gözlemlenmektedir.

Tablo 4.20 K-ortalamalar kümeleme ile alınan DVM, ÇSGS ve birleştirilmiş sistem başarımı sonuçları (DC Mall) (%)

				Sınıflayıcı				
				SVM	KSRC	Kombine Sistem	KFKT [153] gauss	KFKT [153] laplacian
Pencere Büyüklüğü	1x1	Etiketli Örnek Sayısı	5	98.84	99.29	99.50	96.18	97.95
			15	98.75	99.31	99.55	97.37	98.79
			30	98.75	99.27	99.52	99.24	99.33
			50	98.95	99.29	99.57	99.90	99.85
	3x3	Etiketli Örnek Sayısı	5	99.26	99.47	99.66	96.18	97.95
			15	99.31	99.47	99.65	97.37	98.79
			30	99.27	99.42	99.62	99.24	99.33
			50	99.27	99.47	99.66	99.90	99.85
	5x5	Etiketli Örnek Sayısı	5	99.62	99.49	99.73	96.18	97.95
			15	99.62	99.44	99.72	97.37	98.79
			30	99.62	99.47	99.74	99.24	99.33
			50	99.62	99.53	99.74	99.90	99.85
	7x7	Etiketli Örnek Sayısı	5	99.67	99.69	99.74	96.18	97.95
			15	99.67	99.71	99.74	97.37	98.79
			30	99.67	99.75	99.84	99.24	99.33
			50	99.67	99.75	99.84	99.90	99.85
	9x9	Etiketli Örnek Sayısı	5	99.58	99.31	99.66	96.18	97.95
			15	99.58	99.33	99.65	97.37	98.79
			30	99.58	99.29	99.66	99.24	99.33
			50	99.58	99.26	99.64	99.90	99.85

Sistem eksiltici kümele ile ilklendirildiğinde DC Mall verisi için alınan DVM, ÇSGS ve birleştirilmiş sistem başarımı sonuçları ve karşılaştırılan KFKT tabanlı yöntemlerin sonuçları Tablo 4.21’ de bulunmaktadır. Birleştirilmiş sistem başarımı DVM ve ÇSGS ile alınan sonuçlardan daha başarılıdır. Tüm etiketli örnek sayıları için birleştirilmiş sistem sonuçlarının en yüksek başarımları verdiği gözlemlenmektedir. Bazı noktalarda alınan sistem başarımı ve ÇSGS başarımının eşit olduğu göze çarpmaktadır.

Sistem k-ortalamalar kümele ile ilklendirildiğinde Pavia Üniversite verisi için alınan DVM, ÇSGS ve birleştirilmiş sistem başarımı sonuçları ve karşılaştırılan KFKT tabanlı yöntemlerin sonuçları Tablo 4.22’ de bulunmaktadır. Birleştirilmiş sistem başarımı DVM ve ÇSGS ile alınan sonuçlardan daha başarılıdır. Tüm etiketli örnek sayıları için birleştirilmiş sistem sonuçlarının en yüksek başarımları verdiği gözlemlenmektedir. Bazı noktalarda alınan sistem başarımı ve ÇSGS başarımının eşit olduğu göze

Tablo 4.21 Eksiltici kümeleme ile alınan DVM, ÇSGS ve birleştirilmiş sistem başarımları sonuçları (DC Mall) (%)

				Sınıflayıcı				
				SVM	KSRC	Kombine Sistem	KFKT [153] gauss	KFKT [153] laplacian
Pencere Büyüklüğü	1x1	Etiketli Örnek Sayısı	5	99.18	99.43	99.49	96.18	97.95
			15	99.34	99.49	99.56	97.37	98.79
			30	99.24	99.47	99.53	99.24	99.33
			50	99.59	99.47	99.93	99.90	99.85
	3x3	Etiketli Örnek Sayısı	5	99.58	99.56	99.64	96.18	97.95
			15	99.86	99.90	99.90	97.37	98.79
			30	99.81	99.90	99.91	99.24	99.33
			50	99.95	99.94	99.96	99.90	99.85
	5x5	Etiketli Örnek Sayısı	5	99.71	99.59	99.71	96.18	97.95
			15	99.72	99.66	99.73	97.37	98.79
			30	99.97	100	100	99.24	99.33
			50	99.99	100	100	99.90	99.85
	7x7	Etiketli Örnek Sayısı	5	99.83	99.84	99.86	96.18	97.95
			15	99.80	99.81	99.84	97.37	98.79
			30	99.80	99.83	99.85	99.24	99.33
			50	99.99	100	100	99.90	99.85
	9x9	Etiketli Örnek Sayısı	5	99.84	99.56	99.84	96.18	97.95
			15	99.72	99.61	99.75	97.37	98.79
			30	99.77	99.64	99.80	99.24	99.33
			50	99.90	99.82	99.92	99.90	99.85

çarpmaktadır. DVM ve ÇSGS sonuçlarının birleştirilmesi ile başarımın bazı etiketli örnek sayıları için %7' ye kadar arttığı tabloda gösterilmiştir.

Sistem eksiltici kümeleme ile ilklendirildiğinde Pavia Üniversite verisi için alınan DVM, ÇSGS ve birleştirilmiş sistem başarımları sonuçları ve karşılaştırılan KFKT tabanlı yöntemlerin sonuçları Tablo 4.23' te bulunmaktadır. Birleştirilmiş sistem başarımları DVM ve ÇSGS ile alınan sonuçlardan daha başarılıdır. Tüm etiketli örnek sayıları için birleştirilmiş sistem sonuçlarının en yüksek başarımları verdiği gözlemlenmektedir. Bazı noktalarda alınan sistem başarımları ve ÇSGS başarımlarının eşit olduğu göze çarpmaktadır. DVM ve ÇSGS sonuçlarının birleştirilmesi ile başarımın bazı etiketli örnek sayıları için %6' ya kadar arttığı tabloda gösterilmiştir. Tablo 4.23 bir önceki tablo olan Tablo 4.22 ile karşılaştırıldığında eksiltici kümeleme ile alınan sonuçların k-ortalamları ile ilklendirmeye göre daha başarılı olduğu gözlemlenmektedir.

4.6.4 Tüm Verinin Graf Tabanlı Sınıflandırılması

AVIRIS Indian Pine (16 sınıf) verisi ile yarı güdümlü öğrenme ile yapılan deneylerde sınıflama başarımları Tablo 4.24' te gösterilmektedir. Tabloda standart k-ortalamları,

Tablo 4.22 K-ortalamlar kümeleme ile alınan DVM, ÇSGS ve birleştirilmiş sistem başarımları sonuçları (Pavia Üniversitesi) (%)

				Sınıflayıcı			
				SVM	KSRC	Kombine Sistem	LapSSNN + NGL [154]
Pencere Büyüklüğü	1x1	Etiketli Örnek Sayısı	5	78.15	79.02	84.46	76.8 ± 1.45
			15	78.54	78.58	84.36	79.5 ± 2.48
			30	77.88	78.43	84.08	80.3 ± 0.87
			50	79.13	78.47	84.73	N/A
	3x3	Etiketli Örnek Sayısı	5	81.04	80.12	85.10	76.8 ± 1.45
			15	80.84	80.12	85.03	79.5 ± 2.48
			30	81.82	80.84	85.30	80.3 ± 0.87
			50	82.25	80.85	85.78	N/A
	5x5	Etiketli Örnek Sayısı	5	82.96	77.73	87.44	76.8 ± 1.45
			15	83.44	77.71	87.43	79.5 ± 2.48
			30	83.68	77.42	87.26	80.3 ± 0.87
			50	83.58	77.42	87.84	N/A
	7x7	Etiketli Örnek Sayısı	5	84.14	80.22	88.09	76.8 ± 1.45
			15	84.75	80.27	88.10	79.5 ± 2.48
			30	84.67	80.20	88.58	80.3 ± 0.87
			50	85.27	79.93	88.55	N/A
	9x9	Etiketli Örnek Sayısı	5	85.01	83.93	88.84	76.8 ± 1.45
			15	85.19	84.00	88.80	79.5 ± 2.48
			30	84.74	83.79	88.73	80.3 ± 0.87
			50	84.11	83.74	88.79	N/A

değiştirilmiş k-ortalamlar ve eksiltici kümeleme ile alınan başarımları sonuçları raporlanmıştır. 1, 3, 5, 7 ve 9 pencere boyutları ve 5, 10, 15 etiketli örnek için alınan sonuçlarda pencere boyutu ve alınan etiketli örnek sayısı arttıkça başarımın arttığı görülmektedir. Ayrıca, eksiltici kümelemenin k-ortalamlar ile ilklendirmeden daha başarılı olduğu gözlemlenmiştir.

Karşılaştırılan diğer 3 yöntem de yapısı itibariyle graf tabanlı yöntemlerdir. Bu yöntemlerden ilki olan gaussian fields and harmonic functions sum of minimum distance locally linear embedding spatial regularization (GFHF-SMD-LLE-SpaReg) hem uzamsal hem de spektral düzlemde ayrı ayrı düzenleyici model kullanmaktadır. Diğer yöntem olan hyperedge weight (HG-W) algoritması uzamsal ve spektral bilgiyi göz önünde bulundurarak bir hiper-graf oluşturmaktadır. Bahsedilen çalışmada alınan en başarılı sonuçlar uzamsal boyutta 12 komşu örneğin kullanılmasıyla alınmıştır. Son karşılaştırma çalışması olan spatial-spectral information-based semisupervised classification (S2ISC) yönteminde gabor filtresi ile uzamsal bilgiyi kullanarak destek vektör makineleri (DVM) ile etiketsiz veriler etiketlenmektedir. Tablo 4.24' te görüldüğü gibi önerilen sistem HG-W ve S2ISC tabanlı yöntemlerden daha başarılı sonuçlar vermiştir. GFHF-SMD-LLE-SpaReg daha yüksek etiketli örnek sayıların daha

Tablo 4.23 Eksiltici kümeleme ile alınan DVM, ÇSGS ve birleştirilmiş sistem başarımları (Pavia Üniversitesi) (%)

				Sınıflayıcı			
				SVM	KSRC	Kombine Sistem	LapSSNN + NGL [154]
Pencere Büyüklüğü	1x1	Etiketli Örnek Sayısı	5	77.99	80.34	85.89	76.8 ± 1.45
			15	78.90	78.72	85.04	79.5 ± 2.48
			30	78.06	80.23	85.66	80.3 ± 0.87
			50	78.53	80.72	85.72	N/A
	3x3	Etiketli Örnek Sayısı	5	82.27	82.12	86.57	76.8 ± 1.45
			15	82.81	82.98	87.04	79.5 ± 2.48
			30	83.30	82.62	86.22	80.3 ± 0.87
			50	83.32	82.52	86.17	N/A
	5x5	Etiketli Örnek Sayısı	5	83.52	80.00	88.58	76.8 ± 1.45
			15	83.62	80.02	88.36	79.5 ± 2.48
			30	83.84	79.99	88.51	80.3 ± 0.87
			50	83.50	80.52	88.69	N/A
	7x7	Etiketli Örnek Sayısı	5	84.52	82.70	88.68	76.8 ± 1.45
			15	84.60	82.83	89.07	79.5 ± 2.48
			30	84.21	82.72	89.29	80.3 ± 0.87
			50	84.16	82.75	89.28	N/A
	9x9	Etiketli Örnek Sayısı	5	86.36	85.03	89.73	76.8 ± 1.45
			15	86.03	85.02	90.33	79.5 ± 2.48
			30	86.76	85.03	90.37	80.3 ± 0.87
			50	86.24	85.03	90.33	N/A

başarılı olmakla birlikte daha küçük etiketli örnek sayılarında önerilen sistem sonuçları daha başarılıdır.

AVIRIS Indian Pine (16 sınıf) verisi ile yarı güdümlü öğrenme ile yapılan deneylerde bazı sınıflardaki örnek kısıtlaması sebebiyle en fazla 15 etiketli örnek ile ilklendirme gerçekleştirilebilmektedir. Indian Pines veri kümesinin sıkça kullanılan küçük örnek sayısına sahip 9 sınıflı versiyonuyla alınan sonuçlar Tablo 4.25’ de gösterilmiştir. Tabloda standart k-ortalamlar, değiştirilmiş k-ortalamlar ve eksiltici kümeleme ile alınan başarımları sonuçları raporlanmıştır. 1, 3, 5, 7 ve 9 pencere boyutları ve 5, 10, 15, 20, 30 ve 50 etiketli örnek için alınan sonuçlarda pencere boyutu ve alınan etiketli örnek sayısı arttıkça başarımın arttığı görülmektedir. Ayrıca, eksiltici kümelemenin k-ortalamlar ile ilklendirmeden daha başarılı olduğu gözlemlenmiştir.

Pavia Üniversite verisi ile yarı güdümlü öğrenme ile yapılan deneylerde sınıflama başarımları Tablo 4.26’ da gösterilmektedir. Tabloda değiştirilmiş k-ortalamlar ve eksiltici kümeleme ile alınan başarımları sonuçları raporlanmıştır. 1, 3, 5, 7 ve 9 pencere boyutları ve 5, 10, 15, 20, 30 ve 50 etiketli örnek için alınan sonuçlarda pencere boyutu ve alınan etiketli örnek sayısı arttıkça başarımın arttığı görülmektedir. Ayrıca, eksiltici kümelemenin k-ortalamlar ile ilklendirmeden daha başarılı olduğu gözlemlenmiştir.

gözlemlenmiştir.

Tablo 4.24 Standart k-ortalamlar, modifiye k-ortalamlar ve eksiltici kümeleme ile alınan sistem başarımları sonuçları (Indian Pines – 16 sınıf) (%)

				Sınıflayıcı			
						Standart K-ortalamlar	Optimize K-ortalamlar
Pencere Büyüklüğü	1x1	Etiketli Örnek Sayısı	5	75.71±0.06	75.83	76.18	N/A
			10	75.91±0.13	76.14	76.42	N/A
			15	76.21±0.07	76.41	76.83	N/A
	3x3		5	86.27±0.05	86.31	86.64	85.22
			10	86.51±0.05	86.54	86.84	90.45
			15	86.66±0.07	86.79	87.04	91.19
	5x5		5	95.30±0.04	95.39	95.76	87.25
			10	95.50±0.05	95.53	95.89	92.92
			15	95.68±0.04	95.70	95.99	94.27
	7x7		5	98.45±0.05	98.55	98.87	86.40
			10	98.55±0.09	98.63	98.95	90.17
			15	98.59±0.08	98.72	98.98	91.19
	9x9		5	98.98±0.06	99.06	99.42	N/A
			10	99.08±0.07	99.15	99.46	N/A
			15	99.14±0.06	99.20	99.49	N/A

				HG-W [156]	BT-SSISC [157]		
Komşu Sayısı	12	Etiketli Örnek Sayısı	5	76.12	N/A		
			10	78.47	N/A		
			15	80.82	N/A		
	0		10	N/A	67.70		
	20		10	N/A	70.66		
	40		10	N/A	71.73		
	60		10	N/A	72.59		
	80		10	N/A	73.30		
	100		10	N/A	75.60		
	120		10	N/A	75.92		

Karşılaştırılan diğer 3 yöntem de yapısı itibariyle graf tabanlı yöntemlerdir. Bu yöntemlerden ilki olan gaussian fields and harmonic functions sum of minimum distance locally linear embedding spatial regularization (GFHF-SMD-LLE-SpaReg) hem uzamsal hem de spektral düzlemde ayrı ayrı düzenleyici model kullanmaktadır. Diğer yöntem olan hyperedge weight (HG-W) algoritması uzamsal ve spektral bilgiyi göz önünde bulundurarak bir hiper-graf oluşturmaktadır. Bahsedilen çalışmada alınan en başarılı sonuçlar uzamsal boyutta 12 komşu örneğin kullanılmasıyla alınmıştır.

Son karşılaştırma çalışması olan spatial-spectral information-based semisupervised classification (S2ISC) yönteminde gabor filtresi ile uzamsal bilgiyi kullanarak destek vektör makineleri (DVM) ile etiketsiz veriler etiketlenmektedir. Tablo 4.26' da görüldüğü gibi önerilen sistem HG-W ve S2ISC tabanlı yöntemlerden daha başarı sonuçlar vermiştir. GFHF-SMD-LLE-SpaReg daha yüksek etiketli örnek sayılarının daha başarılı olmakla birlikte daha küçük etiketli örnek sayılarında önerilen sistem sonuçları daha başarılıdır.

Tüm veri kümelerinde uzamsal bilgi arttıkça başarının arttığı gözlemlenmiştir. Bunun yanında eksiltici kümeleme k-ortalamlar kümelemeye oranla daha başarılı sonuçlar ortaya koymuştur. GÜDÜMLÜ sınıflamada olduğu gibi etiketli örnek sayısı arttıkça başarı artımı sağlanmıştır.

Bu bölümde yapılan çalışma daha çok GPU uygulaması şeklinde gerçekleştirilmiştir. Bunun temel amacı, gelişen hesaplama gücüyle daha farklı yaklaşımlar ortaya koymaktır. Bu noktada daha önce central processing unit (CPU) ile gerçekleştirilemeyen testler gerçekleştirilmiştir.

Yarı-güdümlü öğrenme yöntemleri temel olarak greedy (açgözlü) yaklaşımı temel almaktadır. Yani bulunan durumda en iyi ve en çok kazanç sağlayacak bir sonraki duruma geçmeyi hedeflemektedir. Bu durumdan dolayı özellikle artımsal yaklaşım tabanlı yöntemlerde tüm olasılıklar değerlendirilmelidir, bu da çok fazla hesaplama gücü gerektirmektedir. Diğer yandan pencere boyutunun artması maliyeti parabolik bir şekilde yükseltmektedir. Aynı zamanda yüksek spektral çözünürlük daha fazla bilgi sağlamanın yanında, uzamsal olarak alınan pencerelerle beraber bir hesaplama problemini de beraberinde getirmektedir.

Farklı veri kümeleri için yapılan çalışmalar yöntemlerin başarılı olması için yüksek uzamsal çözünürlüğün bir gereklilik olduğu göstermektedir. Düşük uzamsal çözünürlükte yarı-güdümlü öğrenme başarımları ve buna bağlı olarak sınıflama başarımları çarpıcı bir şekilde düşmektedir.

4.7 Sonuç ve Öneriler

Veri etiketlemenin/yer-gerçekliği oluşturma zorluğu ve maliyeti diğer alanlarda olduğu gibi hiperspektral görüntülemenin de en önemli problemlerinden biridir. Daha önceki bölümde olduğu gibi bu bölümde de yapılan çalışmada YGÖ ve farklı sınıflayıcıların birleşimi ile az sayıdaki etiketli veriyle yüksek sistem başarımları hedeflenmiştir. Gürültü ve hatalı eğitim verisinde SGS' nin gürültüye ve eksik veriye dayanıklılığından, gürültüsü giderilmiş ve görece doğru eğitim verisine sahip olunan

Tablo 4.25 Standart k-ortalamlar, modifiye k-ortalamlar ve eksiltici kümeleme ile alınan sistem başarımları sonuçları (Indian Pines – 9 sınıf) (%)

				Sınıflayıcı		
				Standart K-ortalamlar	Optimize K-ortalamlar	Eksiltici Kümeleme
Pencere Büyüklüğü	1x1	Etiketli Örnek Sayısı	5	77.94±0.04	78.93	79.02
			10	78.07±0.04	79.14	79.19
			15	78.19±0.07	79.25	79.38
			20	78.37±0.05	79.41	79.59
			30	78.38±0.25	79.73	79.99
			50	78.91±0.28	80.23	80.70
	3x3	Etiketli Örnek Sayısı	5	87.30±0.01	88.34	88.33
			10	87.42±0.05	88.51	88.46
			15	87.58±0.05	88.60	88.65
			20	87.65±0.08	88.68	88.80
			30	87.86±0.09	88.93	89.05
			50	88.18±0.14	89.16	89.42
	5x5	Etiketli Örnek Sayısı	5	95.47±0.02	96.50	96.42
			10	95.55±0.05	96.60	96.52
			15	95.61±0.06	96.67	96.59
			20	95.69±0.05	96.72	96.62
			30	95.76±0.07	96.80	96.70
			50	95.92±0.11	96.98	96.88
	7x7	Etiketli Örnek Sayısı	5	98.11±0.02	99.06	99.12
			10	98.19±0.02	99.09	99.19
			15	98.23±0.02	99.09	99.17
			20	98.24±0.03	99.15	99.24
			30	98.33±0.05	99.21	99.30
			50	98.40±0.07	99.30	99.40
	9x9	Etiketli Örnek Sayısı	5	98.50±0.01	99.43	99.50
			10	98.53±0.02	99.49	99.56
			15	98.56±0.02	99.49	99.58
			20	98.58±0.02	99.56	99.58
			30	98.60±0.02	99.56	99.58
			50	98.64±0.04	99.61	99.62

durumlarda DVM' nin güçlü sınıflama özelliğinden faydalanılarak birleştirilmiş bir sistem oluşturulmuştur. SGS' nin genel olarak DVM' den, YGÖ' den elde edilen eğitim kümesiyle sınıflama yaptığı daha başarılı sonuçlar elde edilmiştir. Bunlar dışında evrimsel sinir ağlarının diğer alanlarda olduğu gibi uzaktan algılama alanında da diğer sınıflayıcıların üstünde olduğu gözlemlenmiştir. Derin sınıflayıcının tek başına diğer sınıflayıcılardan daha iyi olduğu gibi, derin sınıflayıcının diğer sınıflar ile birleştirilmesiyle çok daha yüksek başarımların elde edilebileceği ortaya koyulmuştur.

Tablo 4.26 Modifiye k-ortalamlar ve eksiltici kümeleme ile alınan sistem başarımları sonuçları (Pavia Üniversitesi) (%)

	Sınıflayıcı					
				Optimize K-ortalamlar	Eksiltici Kümeleme	GFHF-SMD-LLE-SpaReg [155]
Pencere Büyüklüğü	1x1	Etiketli Örnek Sayısı	5	89.97	89.98	N/A
			10	89.99	89.99	N/A
			15	90.00	90.00	N/A
			20	90.01	90.01	N/A
			30	90.05	90.02	N/A
			50	90.08	90.10	N/A
	3x3		5	96.01	96.01	82.13
			10	96.02	96.02	88.79
			15	96.01	96.03	90.57
			20	96.02	96.03	92.34
			30	96.04	96.04	94.04
			50	96.06	96.05	95.53
	5x5		5	98.26	98.27	91.13
			10	98.27	98.28	95.04
			15	98.28	98.28	96.31
			20	98.29	98.29	97.66
			30	98.29	98.30	98.01
			50	98.30	98.31	98.79
	7x7		5	99.08	99.07	96.88
			10	99.09	99.08	97.51
			15	99.08	99.08	98.16
			20	99.09	99.08	99.01
			30	99.09	99.09	99.21
			50	99.11	99.10	99.36
	9x9		5	99.50	99.50	N/A
			10	99.50	99.50	N/A
			15	99.50	99.51	N/A
			20	99.51	99.51	N/A
			30	99.51	99.51	N/A
			50	99.51	99.51	N/A

				HG-W [156]	BT-SSISC [157]	
Komşu Sayısı	12	Etiketli Örnek Sayısı	5	82.49	N/A	
			10	87.46	N/A	
			15	88.05	N/A	
			20	88.64	N/A	
			30	90.53	N/A	
			50	91.72	N/A	
	0		10	N/A	88.51	
	20		10	N/A	93.93	
	40		10	N/A	94.90	
	60		10	N/A	95.17	
	80		10	N/A	95.13	
	100		10	N/A	95.06	
	120		10	N/A	95.02	

Burada geleneksel sinir ağlarında olduğu gibi derin sınıflayıcılarda da sınıflayıcı veridiği sınıf olasılık bilgisinde genel olarak emin olmadığı örneklerde hata yaptığı gözleminde yola çıkılarak sınıflayıcı birleşimi yapılmıştır.

Daha önce yapılan çalışmalarda edilen tecrübelerle YGÖ için etiketleme kriterinin yanında etiketli verilerin seçiminin başarımı en az etiketleme kadar etkilediği görülmüştür ve yapılan çalışmalarda etiketli veri seçimine yoğunlaşmıştır. Daha önceki bölümlerde odaklanılan bu çalışmaların yanı sıra bu bölümde teknolojinin geldiği en iyi nokta olan derin sınıflayıcılar eğilinmiştir. Farklı veri kümeleri için yapılan deneylerde etiketli örnek seçiminin önemi görülmüştür ve bu da yapılmış diğer çalışmalarla karşılaştırılmıştır, diğer çalışmalardan daha başarılı sonuçlar verdiği görülmüştür.

Spektral bilginin yanında uzamsal bilginin de kullanımının başarımı artırdığı gözlemlenmiştir. Fakat uzamsal bilgiyi kullanmak adına pencere boyutunu fazla büyütmenin de çeşitliliği çok fazla artırdığı ve odak pikselden uzaklaşılmasında dolayı başarımın düşük sayıdaki etiketli veriler için düştüğü gözlemlenmiştir. Ayrıca uzamsal çözünürlüğü düşük olan veri kümelerinde uygulanan yöntemlerin diğer veri kümelerinde olduğu gibi yüksek başarımlı sağlamadığı sonucuna varılmıştır. Özellikle eksiltici kümeleme düşük uzamsal çözünürlükte dikkat çekici bir şekilde başarımlı kaybına uğramaktadır.

Uygulanan yarı-güdümlü öğrenmenin daha güçlü sınıflayıcı ile birleştiğinde daha başarılı sonuçlar verdiği gözlemlenmiştir. Ayrıca bu sınıflayıcının diğer sınıflayıcılar ile entegre bir şekilde daha güçlü bir hale geldiği ortaya koyulmuştur. Bunun yanında uzamsal çözünürlüğün sistemin çalışmasına etkisi araştırılmıştır. Yüksek uzamsal çözünürlüğün ve örnek saflıklarının sistemin çalışmasında önemli bir faktör olduğu alınan sonuçlarla desteklenmiştir.

Yüksek spektral çözünürlüğün hesaplama maliyetine olumsuz etkisinden dolayı tüm veri kümelerinde planlanan sınıflama sonuçların tamamı elde edilememiştir. Sistemin daha iyi çalışabilmesi için tasarımda optimizasyonlar yapılmıştır. Dinamik programlama tabanlı bir yapıya geçilerek yarı-güdümlü öğrenmede 10 kat hızlanma sağlanmıştır. Bunun yanında derin öğrenmede veri kümelerine uygun olacak şekilde varolan ağ yapılarında değişiklikler yapılarak kullanılmıştır. GPU programlama yardımıyla hesaplama gücü dar boğazının ortadan kaldırılabilmesi bu sayede farklı yaklaşımların ortaya koyulabileceği görülmüştür.


Derin Öğrenme Tabanlı Yarı-Güdümlü Öğrenme

Bu bölümde son yıllarda çok revaçta olan derin öğrenme(deep learning) yöntemi temel alınarak çalışmalar gerçekleştirilmiştir. Derin öğrenme kullanıma ilk olarak nesne tanıma başarılarını kanıtlamış olan Alexnet ve VGG hazır ağlarını kullanarak başlanmıştır fakat nesne tanıma problemi ile hiperspektral veri sınıflamanın farklılığı ve bahsedilen ağların (özellikle VGG) hesaplama maliyetlerinin yüksekliğinden dolayı yapılan çalışmaların analizi sonrasında vazgeçilmiştir.

Derin öğrenmede ağ yapısındaki parametre fazlalığından dolayı veri miktarının fazla olması gerekmektedir. Tüm alanlarda olduğu gibi hiperspektral görüntü işleme alanında da etiketli veri kısıtı temel problemlerden biridir. Bu problemin üstesinden gelmek için transfer öğrenme (transfer learning) ortaya atılmıştır. Transfer öğrenmede temel olarak amaç hazır ağ modelinin son katmanı olan sınıflama katmanının değiştirilerek yeni bir probleme eğitilmiş bir modelin uyarlanmasıdır. Yapılan çalışmalarda ilk olarak bir nesne modeli olan Alexnet' e transfer öğrenme diğer adıyla fine tuning (ince ayar) uygulanmıştır. Yapılan bu çalışmada giriş verisinin hazır model kullanılmasından dolayı 224x224x3 olması ve bu nedenle fazladan ve gereksiz şekilde oluşan hesaplama maliyetinden dolayı vazgeçilmiştir. Normal şartlarda 3 boyutlu bir veri olan hiperspektral görüntüler, piksel bazında sınıflama yapıldığında 1 boyutlu bir veri yani piksel vektörü haline gelmektedir. Alexnet gibi renkli nesne görüntülerinin sınıflandırılması için kullanılan bir model için hiperspektral görüntülerdeki piksel vektörlerinin her birinin 3 bant içeren Alexnet için 224x224 boyundaki bir görüntüye dönüştürülmesi gerekmektedir. Temel problemlerden biri bu dönüşümün eğer böyle bir model kullanılacaksa nasıl gerçekleşeceği. İkinci bir problem de hazır olan ağ modelindeki filtre büyüklüklerinin uygulanan alan olan hiperspektral verilere uygun olup olmadığıdır. Yapılan deneyler sonucunda bu şekilde hazır nesne modellerinin filtre büyüklüklerinin piksel bazında hiperspektral veri sınıflamasında uygun olmadığı görülmüştür.

5.1 Derin Öğrenme Tabanlı Öznitelik Çıkarma Yapısı

Bu bölümde yapılan çalışmaların temelini piksel vektörlerinin derin öğrenme ağına uygun bir girdi olacak şekilde dönüştürülmesi, hiperspektral piksel sınıflaması için uygun model yapısının kurulması, kurulan derin modelin yarı-güdümlü öğrenmeye nasıl uygulanacağı üzerine odaklanılmıştır.




Şekil 5.1 Piksel vektörünün iki boyutlu görüntüye dönüşümü

Hiperspektral görüntülerin piksel tabanlı olarak convolutional neural network(konvolüsyonel sinir ağı) ile sınıflanabilmesi için 2 temel problem vardır. 2 boyutlu konvolüsyon uygulanabilmesi için verinin 2 boyutlu bir veri haline getirilmesi gerekmektedir. Bunun için uzamsal bilginin kullanılması ve kullanılmaması durumlarına göre 2 farklı dönüşüm gerçekleştirilmiştir.

5.1.1 Piksel Vektörlerinin İki Boyutlu Görüntülere Dönüşümü

Uzamsal bilgi kullanılmadığında D adet spektral banta sahip bir veri kümesinden bir piksel alındığında elde edilecek vektör $1 \times 1 \times D$ büyüklüğünde olacaktır. Bu vektörün 2 boyutlu görüntüye dönüşüm işlemi dairesel değişim işlemi uygulanarak gerçekleştirilmiştir. Dönüşüm işlemi sonunda $D \times D$ boyutlu bir görüntü elde edilmektedir. Dönüşüm işleminin temel yapısı Şekil 5.1' de gösterilmektedir.




Şekil 5.2 Piksel küpünün iki boyutlu görüntüye dönüşümü

Eğer dönüşüm yapacağımız pikseli komşulukları ile birlikte kullanacaksak dairel dönüşüm işlemi olmadan merkez pikselin yoğunluklu olduğu bir dönüşüm işlemi gerçekleştirilmiştir. $3 \times 3 \times D$ boyutlu bir küp aldığımızda bunun $D \times D$ boyutlu bir dönüşüm işlemi gerçekleştirilmektedir. Bu işlemin genel yapısı Şekil 5.2 ile gösterilmektedir. Bu şekilde merkez piksel yoğunluklu bir yapının seçilmesinin sebebi dönüşüm gerçekleştirilirken merkez pikselin yani sınıflanması hedeflenen pikselin tüm komşuluk değerlerinin korunması temel amaçtır.

5.1.2 Derin Model Ağı Tasarımı ve Kullanımı

Piksel dönüşümleri gerçekleştirilmiş görüntülerin üzerinde yapılan deneysel çalışmaların sonucunda 5 katmanlı bir ağ tasarlanmıştır. Ağ yapısında 3 adet konvolüsyon katmanı 2 adet de tam bağlı (fully connected) öznitelik katmanı bulunmaktadır. Genel ağ yapısı Şekil 5.3’ te gösterilmektedir. Konvolüsyon katmanlarının her birinde 128 adet filtre bulunmaktadır. Tam bağlı olan öznitelik çıkarım katmanlarının ilki 128 adet düğüme, ikinci olan ve bu çalışmada öznitelik

çıkarımı için kullanılan ikinci tam bağlı katman ise 64 düğüme sahiptir. Tüm konvolüsyon katmanlarının ardından rectified linear unit(ReLU – doğrusal düzeltme birimi) uygulanmıştır. Konvolüsyon katmanlarındaki adım (stride) büyüklüğü 2 olarak seçilmiştir. Tam bağlı ilk katman olan fc4 katmanının ardından rastgele budama yapan dropOut katmanını bulunmaktadır. Tam bağlı ikinci katman olan fc5 katmanı 64 düğüme sahip olup öznitelik çıkarımı için kullanılmıştır. Sınıf sayısı ile aynı sayıda düğüme sahip olan sınıflama katmanının kullanılan fonksiyon Softmax fonksiyonudur.



Şekil 5.3 Kullanılan derin ağ yapısı

Yapılan çalışmada derin öğrenme modeli öznitelik çıkarımı için kullanılmıştır. Bunun için de gerçekleştirilen işlem aynı sensör ile elde edilen verilerden bir tanesi ile modelin eğitilmesi, diğerinin bu eğitilen model ile özniteliklerinin çıkarılması işlemidir. Fakat aynı sensör ile alınan görüntülerde yapılan düzeltmelerin ardında bile atmosferik etkilerden dolayı farklılıklar oluşmaktadır. Bu noktada daha önce hazır nesne modelleri üzerinde gerçekleştirilen fine tuning (ince ayar) işlemi gerçekleştirilmesi öznitelik çıkarımında önemli bir katkı sağlamaktadır. Bunun için özneliği çıkarılacak veriden küçük bir örnek kümesi alınarak bu işlem gerçekleştirilmektedir.

5.2 Yarı-Güdümlü Öğrenme ve Sınıflama

Öznitelik çıkarım işleminin ardından etiketli örneklerin seçimi için değiştirilmiş k-ortalamlar, subtractive kümeleme, mean-shift kümeleme, k-medoids kümeleme ve DBscan kümeleme yöntemleri kullanılmıştır.

Değiştirilmiş k-ortalamlar yönteminde, her sınıfa ait etiketli veriler seçilirken, o sınıfa ait tüm örnekler uzaklığı en küçük örnek ilk merkez olarak atanır. Etiketli

örnek sayısının yarısı tamamlanana kadar seçilen merkezlere en yakın örnekler seçilir. Bu şekilde tüm etiketli veriyi kapsayacak merkez atamaları yapılır. Etiketli örnek sayısının yarısı tamamlandığında ise daha önce etiketlenen tüm örnekler en uzak örnekler küme merkezi olarak atanır. Bu şekilde etiketli verilerin merkezden ve çevresinden kapsanması amaçlanmıştır. İklendirme işleminin tamamlanmasının ardından standart k-ortalamlar kümeleme yöntemi çalıştırılır.


Subtractive (Eksiltici) öğrenmenin temel olarak çalışma prensibi örnek sayısının en fazla olduğu daha doğru bir ifadeyle örneklerin en yoğun olduğu nokta küme merkezi olarak seçilerek belirlenen bir d yarıçapı içinde kalan örnekleri eksilterek ikinci en yoğun noktayı küme merkezi yaparak yine aynı şekilde eksiltme işlemini gerçekleştirir. Bu işleme hiçbir küme merkezine dâhil olmayan örnek kalmayana kadar devam edilir. Daha sonra önceki yöntemdeki gibi küme merkezlerine en yakın örnekler etiketli örnek olarak atanır.

Mean-shift clustering (MSC - ortalama kaydırma kümeleme) yöntemi parametrik olmayan bir öznitelik uzayı kümeleme yöntemidir [26]. Bu kümeleme yönteminde kümelerin şekli sınırlanmaz ve başlangıçta küme merkezi sayısının belirtilmesine/bilinmesine gerek yoktur. Ancak küme sayısının ayarlanması gerekiyorsa, uygun pencere yarıçapı bulunmalıdır. MSC algoritması, (5.1) eşitliğini kullanarak çekirdek yoğunluğu fonksiyonunun maksimum değere sahip olduğu yeri arar:

$$f(x) = \frac{1}{nh^d} \sum_{i=1}^n K\left(\frac{x-x_i}{h}\right) \quad (5.1)$$

burada n, d boyutlu öznitelik uzayında $(x_i, i=1,...,n)$ gözlem sayısını ifade etmektedir. $K(x)$ ise h pencere yarıçaplı çekirdek fonksiyonunu ifade etmektedir. Pencere öteleme, ortalama kaydırma vektörü ile $x^{t+1} = x^t + m_h(x^t)$ yardımıyla hesaplanır. Ortalama-kaydırma vektörü olan $m_h(x)$, her zaman yoğunluğu maksimize ederek hesaplanır. Öteleme işlemi $\nabla f(x) = 0$ olana kadar devam eder ve $\nabla f(x)$, yoğunluk fonksiyonunun değişimini belirtmektedir.

Mean-shift kümeleme yönteminde, başlangıçta tüm noktalardan bir kümeleme başlatılır ve tanımlanan bir yarıçap içerisindeki örnekler hesaplanarak ortalama yer hesaplanır. Daha sonra küme merkezi ortalama yere doğru kaydırılır ve bu noktada iken tekrar ortalama yer hesaplanır. Bu şekilde en yoğun yere doğru küme merkezi kaydırılır. Algoritmada küme merkezi sayısı veriler yarıçapa göre otomatik olarak belirlenir. Üst üste gelen kümeler birleştirilerek tek bir küme haline getirilir.




Şekil 5.4 DBscan çalışma prensibi

K-medoids kümeleme k-means kümelemeye benzer şekilde çalışmaktadır. Bu kümeleme şeklinde rastgele k adet örnek küme merkezi olarak atanır, sonrasında tüm örnekler kendisine en yakın olan merkeze eleman olarak atanır. Bir sonraki adımda hangi küme elemanı küme merkezine olan toplam uzaklıkları minimum yapıyorsa o küme merkezi yapılır ve kümeler tekrar hesaplanır. Bu işlem küme merkezleri değişmeyene kadar devam eder ve nihai küme merkezleri bulunur.

Dbscan algoritması iki temel parametre almaktadır, bunlardan ilki epsilon değeri, diğeri ise minimum örnek sayısıdır. Algoritmada herhangi bir örnekten başlanarak tüm örnekler kontrol edilir. Kontrol edilen örnek daha önceden bir kümeye atanmışsa hiçbir işlem yapılmaz fakat atanmamış ise epsilon yarıçapındaki komşularına bakar. Bu yarıçap içerisindeki komşuluk sayısı minimum örnek sayısından fazla ise, belirlenen örnek ve komşularından yeni bir küme oluşturulur. Daha sonra, önceden kümelenmemiş her bir komşu için yeni bölge sorgusu yaparak yeni komşular bulur. Bölge sorgusu yapılan noktaların komşu sayıları minimum örnek sayısından fazla ise komşu örnek kümeye dâhil edilir. Şekil 5.4' te yöntemin genel çalışma şekli gösterilmektedir. Burada kırmızı noktalar bir kümeyi A kümesini, sarı noktalar B ve C kümelerini ifade etmektedir. N mavi noktası ise yöntem tarafından gürültü olarak belirlenmiştir. B ve C noktaları merkez örnek olduklarında epsilon yarıçapı içerisinde minimum örnek sayısı kadar örnek içermemektedir fakat minimum örnek sayısı kadar örnek içeren başka bir örnek bu örnekler merkez örnek olduğunda yarıçap içerisinde bulunmaktadır. Dolayısıyla bu örnekler küme olarak belirlenmiştir fakat merkez örnek olduğunda yarıçap içerisinde hiçbir örnek olmayan N örneği ise gürültü olarak işaretlenmiştir.

Konvolüsyonel sinir ağı modelinden elde edilen öznitelik vektörleri, yarı güdümlü destek vektör makinesi olarak bilinen transductive support vector mahine ($TSVM - S^3VM$) kullanılarak sınıflandırılmıştır. TSVM etiketli örnek sayısı çok kısıtlı olduğunda kullanılan, etiketli örneklerin yanında etiketsiz örneklerin de gücünü kullanmayı amaçlayan yarı-güdümlü bir sınıflayıcıdır. Temel çalışma prensibi, hiperdüzlem (hyperplane) ile düzlem ayırımı yapılırken etiketsiz örneklerin konumunun da göz önüne alınmasıyla hiperdüzlemin oluşturulmasıdır. Genel çalışma prensibi Şekil 5.5 ile görülmektedir.



Şekil 5.5 TSVM çalışma prensibi

TSVM, SVM uygulanan her durumda uygulanabilir fakat optimizasyonu zordur ve özellikle etiketli örnek sayısının fazla olduğu durumlarda yanlış çözümlerde hapsolabilir. TSVM' in tüm veri kümesi üzerinde uygulanması optimizasyon probleminden dolayı pek mümkün değildir. Bu nedenle TSVM ile kısıtlı olan etiketli veri sayısı artırılarak sonrasında standart destek vektör makinesi uygulanmaktadır.

Transdüktif destek vektör makineleri diğer bir deyişle yarı-güdümlü destek vektör makineleri (5.2)' de gösterildiği gibi hem etiketli hem de etiketsiz örneklerin bilgisini kullanmaktadır.

$$Y = (y_{L+1}, \dots, y_{L+U}) \quad (5.2)$$

burada L verilen etiketli eğitim kümesini, U ise etiketsiz test kümesini ifade etmektedir. Geleneksel destek vektör makinelerinde, hiperdüzlemler her iki taraftan da kendisine en yakın örneklem ile arasındaki aralığı/marjini en büyük hale getirmeye çalışırlar. TSVM' ler ise etiketli örneklerin yanı sıra her iki taraftan kendisine en yakın etiketsiz örnekler ile de arasındaki mesafeyi maksimize etmeye gayret ederler. Bu haliyle (5.3)' de gösterildiği gibi bir minimizasyon problemi haline gelir:

$$J(\theta) = \frac{1}{2}||w||^2 + C \sum_{i=1}^L \epsilon_i + C^* \sum_{i=L+1}^{L+U} \epsilon_i \quad (5.3)$$

(5.3) eşiliğindeki C^* , 0 olduğunda eşitlik standart bir SVM optimizasyonu haline gelir. $C^* > 0$ olduğu durumda ise marjın içindeki etiketsiz örnekler cezalandırılır. TSVM algoritması küçük örneklem büyüklüğü problemleri için iyi bir çözüm algoritmasıdır fakat hesaplama karmaşıklığı nedeniyle çekirdek destek vektör makineleri için kullanılabilir değildir. Bu noktada, doğrusal olarak ayrılabilen derin öznetelikler bu yöntemin kullanılmasına imkan sağlamaktadır.

TSVM ile yarı-güdümlü öğrenmenin yanı sıra iteratif olarak öğrenen sözlük tabanlı yarı-güdümlü seyrek gösterim sınıflayıcısı ile etiketsiz verilerin etiketlenmesi işlemi gerçekleştirilmiştir. Seyrek gösterim sınıflayıcısında temel olarak elde bulunan bir sözlük ile gelen bir test örneğinin sözlükteki her bir atoma belirli bir ağırlık verilerek tekrar oluşturulabilmesidir. Tüm sınıflardaki atomlar ile bu geri çatma işlemi gerçekleştirilir ve hangi geri çatma işlemi en az hataya sahipse gelen test örneği o sınıfa atanır. Yöntemin genel çalışma prensibi Şekil 3.1' de gösterilmektedir. Yarı-güdümlü öğrenme aşamasında elde bulunan etiketli örnek sayısı kadar etiketsiz örnek her bir adımda etiketlenir ve sözlüğe eklenir. Bu şekilde self-training (kendi kendine öğrenme) gerçekleştirilir. Veri setindeki eğitim örnekleri yarı-güdümlü seyrek gösterim sınıflayıcı ile etiketlenir. Test aşamasında eğitim kümesindeki örnekler sözlüğü oluştururken test setindeki tüm örnekler bir seferde etiketlenir.

5.3 Deneysel Sonuçlar

Hedeflenen sınıflama sisteminin başarımının değerlendirilmesi için kullanılan ilk veri kümesi ROSIS Pavia Üniversitesi verisidir. Pavia Üniversitesi hiperspektral görüntüsü 610x340 boyutlarında olup, 103 spektral bant içermektedir. Bu veride güdümlü sınıflama için 9 sınıfa ait etiketli 3921 eğitim pikseli ve 42776 test pikseli bulunmaktadır. Fakat model eğitimi için yine ROSIS algılayıcısı ile elde edilen ROSIS Pavia Center verisi kullanılmıştır. Pavia Center hiperspektral görüntüsü 1096x1096 boyutlarında olup, 102 spektral bant içermektedir. Bu veride toplam 9 sınıfa ait 148152 etiketli örnek bulunmaktadır.

Sistemin başarımının değerlendirilmesi için kullanılan ikinci veri kümesi AVIRIS Indian Pines hiperspektral verisidir. Indian Pines hiperspektral görüntüsü 145x145 boyutlarında olup, 200 spektral bant içermektedir. Bu veride güdümlü sınıflama için 16 sınıfa ait etiketli 10249 piksel bulunmaktadır ve bu etiketli veriler 30% eğitim ve 70% test olarak rastgele belirlenmiştir. Fakat model eğitimi için yine AVIRIS algılayıcısı

ile elde edilen AVIRIS Salinas verisi kullanılmıştır. Salinas hiperspektral görüntüsü 512x217 boyutlarında olup, 204 spektral bant içermektedir. Bu veride toplam 16 sınıfa ait 52129 etiketli örnek bulunmaktadır.

Rosis ve Aviris sensörleri için modeller sırasıyla Pavia Center ve Salinas verileri ile ‘epoch’=100, ‘InitialLearnRate’ = 0.01, ‘LearnRateDropPeriod’=40 ve ‘LearnRateDropFactor’=0.1 parametreleri olacak şekilde eğitilmiştir. Oluşturulan model ROSIS ve AVIRIS algılayıcılarına ait genel derin modeller olarak ortaya çıkmıştır fakat atmosferik etki farklılıklarının ortadan kaldırılması amacıyla ROSIS Pavia Üniversite verisi ve AVIRIS Indian Pines verisiyle fine-tuning(ince ayar) yapılmıştır. Fine tune işlemi bir alanda oluşturulmuş bir modelin belirli bir veri kümesine uyarlanması işlemidir. Bu noktada fine-tune için Pavia Üniversite verisinin eğitim kümesinde her sınıfta bulunan örneklerden rastgele 10 adet seçilmiştir. Seçilen her sınıfa ait 10 adet örnek kendi içlerinde kaynaştırılarak her sınıfa ait veri sayısı arttırılmıştır. Her örnek için kaynaştırma sonucunda toplam 1000 adet örnek oluşturulmuştur. Kaynaştırma işlemi bir örneğin bant sayısının beşte ikisi kadar rastgele bantın yine aynı sınıfa ait rastgele olarak seçilen başka bir örnekle değiştirilmesiyle gerçekleştirilmektedir. Kullanılan veri kümelerinde bant eksiltme işlemlerinin ardından kalan bant sayısı 102’ dir. Örneğin üçüncü sınıfa ait birinci örneğin, rastgele olarak seçilen 40 bant değerinin yerine yine rastgele olarak seçilen üçüncü sınıfa ait herhangi bir örneğin aynı bantlarda bulunan değerleri ile yeni bir örnek oluşturulur ve bu sayede veri çeşitliliği ve çoğaltımı sağlanır. Fine-tune işlemi ‘epoch’=1000, ‘InitialLearnRate’ = 0.0001, ‘LearnRateDropPeriod’=400 ve ‘LearnRateDropFactor’=0.1 parametreleri olacak şekilde gerçekleştirilir. Her iki kümenin sınıf sayısını aynı olduğu için sınıflama katmanını değiştirilmemiştir. Aynı ince ayar işlemleri AVIRIS Indian Pines veri kümesi için de aynı prosedür izlenerek gerçekleştirilmiştir.

1x1, 3x3, 5x5 ve 7x7 olmak üzere 4 pencere boyutu için testler gerçekleştirilmiştir. 7x7 pencere boyutunda başarımın düşmesinden dolayı daha büyük pencere boyutları için test yapılmamıştır. Her pencere boyutunun kendisi için özel derin modeli oluşturulmuştur.

Sistem işleyişinde öncelikle hem Pavia Center hem de Pavia Üniversite verisindeki etiketli tüm verilerden tüm pencere boyutları için 102x102 boyutunda görüntüler daha önce bahsedildiği şekilde oluşturulmuştur. Her pencere boyutu için Pavia Center verisi ile yapısı Şekil 5.3’ de gösterilen model eğitimi gerçekleştirilir. Eğitilmiş model Pavia Üniversite verisinden rastgele olarak her sınıftan 10 etiketli örnek ve bu örnekler kullanılarak oluşturulan 990 örnek dâhil edilerek fine-tune işlemi gerçekleştirilir. Fine-tune işlemi gerçekleştirilmediğinde 6% başarım kaybı

yaşanmaktadır. Fine-tune işleminin ardında Pavia Üniversite verisindeki tüm örneklerin eğitim modeli kullanılarak öznitelikleri çıkarılır. Öznitelik boyutu tüm pencere boyutları için fc6 katmanının düğüm sayısı olan 64' tür. Normal şartlarda 7x7 pencere boyutu için 7x7x102 yani 4998 olarak ortaya çıkmaktadır.

Pavia Center ve Pavia Üniversite verilerinde olduğu gibi, Salinas ve Indian Pines verisindeki etiketli tüm verilerden tüm pencere boyutları için 200x200 boyutunda görüntüler daha önce bahsedildiği şekilde oluşturulmuştur. Her pencere boyutu için Salinas verisi ile yapısı Şekil 5.3' te gösterilen model eğitimi gerçekleştirilir. Eğitilmiş model Indian Pines verisinden rastgele olarak her sınıftan 10 etiketli örnek ve bu örnekler kullanılarak oluşturulan 990 örnek dâhil edilerek fine-tune işlemi gerçekleştirilir. Fine-tune işlemi gerçekleştirilmediğinde 30% başarımlı kayıp yaşanmaktadır. Fine-tune işleminin ardında Indian Pines verisindeki tüm örneklerin eğitim modeli kullanılarak öznitelikleri çıkarılır. Öznitelik boyutu tüm pencere boyutları için fc6 katmanının düğüm sayısı olan 64' tür. Normal şartlarda 7x7 pencere boyutu için 7x7x200 yani 9800 olarak ortaya çıkmaktadır.

Eğitilmiş model ile öznitelik çıkarımı hiperspektral veriyi doğrusal ayrılabilen bir düzleme taşıdığı gibi öznitelik sayısını da kayda değer bir şekilde azaltmaktadır. Etiketli örnek seçimi için çıkarılan öznitelikler üzerinde kmeans++, subtractive, mean-shift, k-medoids ve DBscan kümeleme yöntemleri kullanılarak Pavia Üniversite verisi için 1,3,5,15 ve 30 etiketli örnek, Indian Pines verisi için 1,3,5 ve 15 etiketli örnek seçimi tüm pencere boyutları için uygulanır. Seçilen örneklerle SVM ve TSVM sınıflama yöntemleri uygulanarak eğitim kümesinin seçilen az sayıdaki etiketli örnek ile sınıflanması gerçekleştirilir. Elde edilen eğitim kümesi ile test kümesinin sınıflanması gerçekleştirilir. SVM kullanılarak seçilen kısıtlı sayıdaki etiketli örnek ile test kümesinin sınıflama sonuçları da elde edilmiştir fakat TSVM yönteminin optimizasyon probleminden dolayı tüm test kümesi ile sonuç alınamamıştır. Hem TSVM' de hem de SVM' de lineer çekirdek uzayı, cost parametresi 0.1, gamma parametresi 0.5 olarak kullanılmıştır. Etiketsiz örneklerin etiketlenmesi için kullanılan bir diğer yöntem de S^3RC yöntemidir. TSVM' de olduğu gibi lineer SRC kullanılmıştır. Yarı-güdümlü öğrenme aşamasında öz-yinelemeli sözlük tabanlı S^3RC kullanılmıştır. Arttırılan eğitim örnekleriyle gerçekleştirilen test aşamasın ise lineer SRC kullanılmıştır.

Pavia Üniversite verisi için gösterilen tabloların üst satırında bulunan 1, 3, 5, 15, ve 30 değerleri başlangıçta seçilen etiketli örnek sayısını belirtmektedir. Tabloların ilk 5 satırı SVM ile alınmış eğitim kümesinin sınıflama başarımlarını göstermektedir. Ortadaki 5 satır ise TSVM ile alınan eğitim kümesi başarımlarını, son 5 satır ise S^3RC ile alınan eğitim kümesi başarımlarını göstermektedir. Eğitim kümesi için SVM, TSVM ve S^3RC başarımları sırasıyla 1x1 pencere boyutu için Tablo 5.1' de, 3x3 pencere boyutu için

Tablo 5.2' de, 5x5 pencere boyutu için Tablo 5.3' te ve 7x7 pencere boyutu için Tablo 5.4' te görülmektedir.

TSVM yapısı itibariyle az sayıdaki etiketli örneklerle başarılı çalıştığı gibi etiketli örnek sayısı arttıkça karmaşıklığı artması ve lokal optimumlara takılma gibi problemlerden dolayı SVM ile karşılaştırıldığında zaman zaman başarımı düşmektedir. Tablolarda her sınıftan bir etiketli veri ile TSVM ve S^3RC yöntemlerinin SVM' e görece çok daha başarılı olduğu görülmektedir. Diğer yandan etiketli örnek sayısı ile SVM yönteminin başarımı kat ve kat artarken diğer yöntemlerin başarımları stabil kalmaktadır.

Tablo 5.1 Pavia Üniversite verisi için farklı etiketli örnek sayıları için 1x1 pencere boyutu için eğitim kümesi sınıflama sonuçları (%)

1x1 Metotlar	1	3	5	15	30
KMC-SVM-Train	0.05	86.43	90.79	95.08	96.08
SC-SVM-Train	0.00	80.44	90.72	95.05	95.54
MSC-SVM-Train	0.00	72.15	86.94	86.20	90.28
Kmedoids-SVM-Train	0.05	79.85	89.77	94.59	96.17
DBscan-SVM-Train	0.05	71.67	75.62	83.98	91.10
KMC-TSVM-Train	87.35	94.06	93.60	95.49	96.69
SC-TSVM-Train	85.54	90.51	95.08	95.00	95.13
MSC-TSVM-Train	91.00	88.37	87.40	90.97	93.34
Kmedoids-TSVM-Train	87.35	94.29	94.62	95.15	96.00
DBscan-TSVM-Train	87.35	84.57	88.16	91.56	93.80
KMC-SRC-Train	94.31	96.69	96.97	95.00	96.76
SC-SRC-Train	92.53	94.75	96.48	97.42	97.35
MSC-SRC-Train	92.48	90.82	91.92	94.49	94.19
Kmedoids-SRC-Train	94.31	96.53	96.94	94.49	97.27
DBscan-SRC-Train	94.31	95.44	93.19	92.25	95.44

Pavia Üniversite verisindeki tüm etiketsiz verilerin başarımlarının gösterildiği tablolarda ilk 5 satır SVM ile alınmış etiketsiz tüm örneklerin sınıflama başarımını göstermektedir. Ortadaki 5 satır ise TSVM ile alınan tüm etiketsiz örneklerin başarımı, son 5 satır ise S^3RC alınan tüm etiketsiz verilerin etiketlenme başarımını göstermektedir. Tüm etiketsiz veriler için SVM, TSVM ve S^3RC başarımları sırasıyla 1x1 pencere boyutu için Tablo 5.5' de, 3x3 pencere boyutu için Tablo 5.6' da, 5x5 pencere boyutu için Tablo 5.7' de ve 7x7 pencere boyutu için Tablo 5.8' de görülmektedir.

TSVM yapısı itibariyle az sayıdaki etiketli örneklerle başarılı çalıştığı gibi etiketli örnek sayısı arttıkça karmaşıklığın artması ve lokal optimumlara takılma gibi problemlerden dolayı SVM ile karşılaştırıldığında zaman zaman başarımı düşmektedir. Tablolarda her sınıftan bir etiketli veri ile TSVM ve S^3RC yöntemlerinin SVM' e görece çok daha

Tablo 5.2 Pavia Üniversite verisi için farklı etiketli örnek sayıları için 3x3 pencere boyutu için eğitim kümesi sınıflama sonuçları (%)

3x3 Metotlar	1	3	5	15	30
KMC-SVM-Train	0.00	92.09	94.64	99.18	99.49
SC-SVM-Train	0.00	86.56	90.84	97.99	98.85
MSC-SVM-Train	0.00	87.48	86.36	99.46	98.90
Kmedoids-SVM-Train	0.00	93.29	95.72	99.29	99.72
DBscan-SVM-Train	0.00	91.56	93.85	94.36	97.42
KMC-TSVM-Train	97.20	99.11	99.49	99.92	99.98
SC-TSVM-Train	98.04	98.67	99.41	99.31	99.46
MSC-TSVM-Train	98.19	97.65	98.52	99.82	99.98
Kmedoids-TSVM-Train	97.20	99.16	99.31	99.87	99.95
DBscan-TSVM-Train	97.20	97.42	97.27	96.17	98.93
KMC-SRC-Train	99.52	99.64	99.72	99.92	99.98
SC-SRC-Train	99.67	99.54	99.62	99.75	99.67
MSC-SRC-Train	99.49	99.72	99.80	99.92	100
Kmedoids-SRC-Train	99.52	99.64	99.75	99.92	100
DBscan-SRC-Train	99.52	99.67	99.75	99.69	99.80

Tablo 5.3 Pavia Üniversite verisi için farklı etiketli örnek sayıları için 5x5 pencere boyutu için eğitim kümesi sınıflama sonuçları (%)

5x5 Metotlar	1	3	5	15	30
KMC-SVM-Train	0.00	93.32	99.11	99.18	99.39
SC-SVM-Train	0.00	92.63	95.05	99.67	99.67
MSC-SVM-Train	0.00	87.50	93.60	99.87	99.98
Kmedoids-SVM-Train	0.00	93.93	96.94	99.69	99.95
DBscan-SVM-Train	0.00	84.32	99.77	97.09	92.76
KMC-TSVM-Train	99.90	99.92	99.98	100	100
SC-TSVM-Train	99.41	99.92	99.95	100	99.95
MSC-TSVM-Train	99.72	99.98	99.77	100	100
Kmedoids-TSVM-Train	99.90	99.95	99.98	100	100
DBscan-TSVM-Train	99.90	100	99.87	99.87	99.98
KMC-SRC-Train	100	100	100	100	100
SC-SRC-Train	100	100	100	100	100
MSC-SRC-Train	100	100	100	100	100
Kmedoids-SRC-Train	100	100	100	100	100
DBscan-SRC-Train	100	100	100	100	100

başarılı olduğu görülmektedir. Diğer yandan etiketli örnek sayısı ile SVM yönteminin başarımları kat ve kat artarken diğer yöntemlerin başarımları stabil kalmaktadır.

Pavia Üniversite verisi için en başarılı sınıflama sonuçları 5x5 pencere boyutunda

Tablo 5.4 Pavia Üniversite verisi için farklı etiketli örnek sayıları için 7x7 pencere boyutu için eğitim kümesi sınıflama sonuçları (%)

7x7 Metotlar	1	3	5	15	30
KMC-SVM-Train	0.00	94.64	98.93	99.92	99.95
SC-SVM-Train	0.00	98.65	97.68	99.34	99.87
MSC-SVM-Train	0.00	92.81	96.53	97.68	100
Kmedoids-SVM-Train	0.00	98.83	98.11	99.59	99.85
DBscan-SVM-Train	0.00	95.05	96.91	93.88	96.30
KMC-TSVM-Train	99.77	99.98	99.92	100	100
SC-TSVM-Train	99.75	99.98	99.98	99.98	99.98
MSC-TSVM-Train	99.92	100	99.98	99.82	100
Kmedoids-TSVM-Train	99.77	99.98	100	100	100
DBscan-TSVM-Train	99.77	99.85	99.87	99.39	99.57
KMC-SRC-Train	100	100	100	100	100
SC-SRC-Train	100	100	100	100	100
MSC-SRC-Train	100	100	100	100	100
Kmedoids-SRC-Train	100	100	100	100	100
DBscan-SRC-Train	100	100	100	100	100

Tablo 5.5 Pavia Üniversite verisi için farklı etiketli örnek sayıları için 1x1 pencere boyutu için tüm etiketsiz örneklerin sınıflama sonuçları (%)

1x1 Metotlar	1	3	5	15	30
KMC-SVM-Test	0.08	80.32	82.62	83.31	85.81
SC-SVM-Test	0.04	79.21	83.45	86.97	87.29
MSC-SVM-Test	0.04	68.73	72.72	75.76	81.40
Kmedoids-SVM-Test	0.08	72.46	83.45	85.10	84.81
DBscan-SVM-Test	0.08	62.37	73.79	75.12	80.62
KMC-TSVM-Test	79.35	84.60	83.57	84.13	84.97
SC-TSVM-Test	73.73	83.20	85.19	85.10	85.81
MSC-TSVM-Test	83.44	81.98	76.21	79.65	83.20
Kmedoids-TSVM-Test	79.35	84.52	85.07	84.47	84.03
DBscan-TSVM-Test	79.35	73.40	77.50	80.19	80.45
KMC-SRC-Test	83.12	84.50	84.77	83.93	83.93
SC-SRC-Test	80.42	84.83	86.01	85.75	85.66
MSC-SRC-Test	82.49	82.85	80.73	81.75	82.15
Kmedoids-SRC-Test	83.12	82.27	85.02	83.84	84.15
DBscan-SRC-Test	83.12	81.29	80.16	82.44	83.10

elde edilmiştir. En ideal uzamsal bilgi bu pencere boyutu için elde edilmiştir. Bunu etkileyen faktörlerden en önemlisi veri kümesinin uzamsal çözünürlüğüdür. Pencere boyutunun artmasının her zaman başarımı arttırmayacağı Tablo 5.7 ile Tablo 5.8

Tablo 5.6 Pavia Üniversite verisi için farklı etiketli örnek sayıları için 3x3 pencere boyutu için tüm etiketsiz örneklerin sınıflama sonuçları (%)

3x3 Metotlar	1	3	5	15	30
KMC-SVM-Test	0.00	86.09	87.92	88.16	88.03
SC-SVM-Test	0.01	85.32	85.23	91.54	92.42
MSC-SVM-Test	0.02	86.90	85.99	89.27	88.00
Kmedoids-SVM-Test	0.00	87.59	86.90	89.61	88.65
DBscan-SVM-Test	0.00	88.08	91.19	89.61	92.21
KMC-TSVM-Test	91.49	90.05	90.18	90.03	90.19
SC-TSVM-Test	88.81	91.62	90.17	90.34	91.79
MSC-TSVM-Test	89.85	90.14	91.90	90.79	90.74
Kmedoids-TSVM-Test	91.49	90.00	89.82	90.29	89.93
DBscan-TSVM-Test	91.49	90.13	91.07	91.83	92.87
KMC-SRC-Test	90.12	90.17	90.17	90.16	90.18
SC-SRC-Test	89.35	90.13	90.17	90.18	90.17
MSC-SRC-Test	90.12	89.49	90.14	91.73	90.18
Kmedoids-SRC-Test	90.12	90.17	90.12	90.16	90.18
DBscan-SRC-Test	90.12	90.10	90.54	92.27	91.32

Tablo 5.7 Pavia Üniversite verisi için farklı etiketli örnek sayıları için 5x5 pencere boyutu için tüm etiketsiz örneklerin sınıflama sonuçları (%)

5x5 Metotlar	1	3	5	15	30
KMC-SVM-Test	0.11	84.09	92.02	91.46	84.83
SC-SVM-Test	0.07	87.19	88.97	90.95	90.12
MSC-SVM-Test	0.11	82.52	86.47	91.25	92.14
Kmedoids-SVM-Test	0.11	86.72	90.28	92.39	90.64
DBscan-SVM-Test	0.11	79.61	91.83	89.67	88.22
KMC-TSVM-Test	90.01	92.13	91.74	92.22	92.22
SC-TSVM-Test	89.17	92.13	92.23	92.22	90.74
MSC-TSVM-Test	90.80	91.95	90.03	92.22	92.22
Kmedoids-TSVM-Test	90.01	92.23	91.74	92.22	92.22
DBscan-TSVM-Test	90.01	92.23	91.19	91.19	91.77
KMC-SRC-Test	91.71	91.71	91.71	91.71	91.71
SC-SRC-Test	91.71	91.71	91.71	91.71	91.71
MSC-SRC-Test	91.71	91.71	91.71	91.71	91.71
Kmedoids-SRC-Test	91.71	91.71	91.71	91.71	91.71
DBscan-SRC-Test	91.71	91.71	91.71	91.71	91.71

birlikte incelendiğinde göze çarpmaktadır.

Pavia Üniversite verisinde olduğu gibi Indian Pines veri kümesi için gösterilen tabloların üst satırında bulunan 1, 3, 5 ve 15 değerleri başlangıçta seçilen etiketli

Tablo 5.8 Pavia Üniversite verisi için farklı etiketli örnek sayıları için 7x7 pencere boyutu için tüm etiketsiz örneklerin sınıflama sonuçları (%)

7x7 Metotlar	1	3	5	15	30
KMC-SVM-Test	0.16	88.70	91.81	91.64	92.50
SC-SVM-Test	0.21	89.66	87.14	84.71	90.10
MSC-SVM-Test	0.15	86.35	88.17	89.58	92.36
Kmedoids-SVM-Test	0.16	89.24	85.44	92.23	92.36
DBscan-SVM-Test	0.16	86.32	85.01	87.44	88.78
KMC-TSVM-Test	89.20	92.28	92.26	92.37	92.37
SC-TSVM-Test	89.48	92.28	92.28	92.28	92.28
MSC-TSVM-Test	92.57	92.37	90.91	83.06	92.36
Kmedoids-TSVM-Test	89.20	92.28	92.37	92.37	92.37
DBscan-TSVM-Test	89.20	90.57	90.45	89.41	91.99
KMC-SRC-Test	91.57	91.57	91.57	91.57	91.57
SC-SRC-Test	91.57	91.57	91.57	91.57	91.57
MSC-SRC-Test	91.57	91.57	91.57	91.57	91.57
Kmedoids-SRC-Test	91.57	91.57	91.57	91.57	91.57
DBscan-SRC-Test	91.57	91.57	91.57	91.57	91.57

örnek sayısını belirtmektedir. Tabloların ilk 5 satırı SVM ile alınmış eğitim kümesinin sınıflama başarımını göstermektedir. Ortadaki 5 satır ise TSVM ile alınan eğitim kümesi başarımı, son 5 satır ise S^3RC ile alınan eğitim kümesi başarımını göstermektedir. Eğitim kümesinin etiketsiz verileri için SVM, TSVM ve S^3RC başarımları sırasıyla 1x1 pencere boyutu için Tablo 5.9' da, 3x3 pencere boyutu için Tablo 5.10' da, 5x5 pencere boyutu için Tablo 5.11' de ve 7x7 pencere boyutu için Tablo 5.12' de görülmektedir.

TSVM yapısı itibariyle az sayıdaki etiketli örneklerle başarılı çalıştığı gibi etiketli örnek sayısı arttıkça karmaşıklığı artması ve lokal optimumlara takılma gibi problemlerden dolayı SVM ile karşılaştırıldığında zaman zaman başarımı düşmektedir. Tablolarda her sınıftan bir etiketli veri ile TSVM ve S^3RC yöntemlerinin SVM' e görece çok daha başarılı olduğu görülmektedir. Diğer yandan etiketli örnek sayısı ile SVM yönteminin başarımı kat ve kat artarken diğer yöntemlerin başarımları stabil kalmaktadır.

Pavia Üniversite olduğu gibi Indian Pines verisindeki tüm etiketsiz verilerin başarımlarının gösterildiği tablolarda ilk 5 satır SVM ile alınmış etiketsiz tüm örneklerin sınıflama başarımını göstermektedir. Ortadaki 5 satır ise TSVM ile alınan tüm etiketsiz örneklerin başarımı, son 5 satır ise S^3RC alınan tüm etiketsiz verilerin etiketlenme başarımını göstermektedir. Tüm etiketsiz veriler için SVM, TSVM ve S^3RC başarımları sırasıyla 1x1 pencere boyutu için Tablo 5.13' te, 3x3 pencere boyutu için Tablo 5.14' te, 5x5 pencere boyutu için Tablo 5.15' de ve 7x7 pencere boyutu için Tablo

Tablo 5.9 Indian Pines verisi için farklı etiketli örnek sayıları için 1x1 pencere boyutu için eğitim kümesi sınıflama sonuçları (%)

1x1 Metotlar	1	3	5	15
KMC-SVM-Train	0.03	83.80	88.64	91.83
SC-SVM-Train	0.09	72.10	86.92	91.00
MSC-SVM-Train	0.03	50.39	62.38	87.70
Kmedoids-SVM-Train	0.03	83.65	87.53	93.63
DBscan-SVM-Train	0.03	50.82	50.04	79.30
KMC-TSVM-Train	92.29	96.56	98.25	97.39
SC-TSVM-Train	92.95	96.87	97.42	97.59
MSC-TSVM-Train	89.91	93.92	95.01	95.84
Kmedoids-TSVM-Train	92.29	97.05	97.65	96.90
DBscan-TSVM-Train	92.29	88.64	88.36	92.57
KMC-SRC-Train	97.28	97.05	98.05	98.34
SC-SRC-Train	95.44	97.19	98.45	98.22
MSC-SRC-Train	96.87	97.25	98.14	97.91
Kmedoids-SRC-Train	97.28	98.08	97.76	98.60
DBscan-SRC-Train	97.28	96.59	95.81	97.94

Tablo 5.10 Indian Pines verisi için farklı etiketli örnek sayıları için 3x3 pencere boyutu için eğitim kümesi sınıflama sonuçları (%)

3x3 Metotlar	1	3	5	15
KMC-SVM-Train	0.00	89.62	93.03	97.88
SC-SVM-Train	0.00	81.53	95.18	97.53
MSC-SVM-Train	0.00	63.35	79.87	92.26
Kmedoids-SVM-Train	0.00	91.94	95.35	97.96
DBscan-SVM-Train	0.00	58.13	70.61	87.84
KMC-TSVM-Train	99.83	99.86	99.86	99.63
SC-TSVM-Train	99.51	99.83	99.86	99.89
MSC-TSVM-Train	99.80	98.54	98.54	99.77
Kmedoids-TSVM-Train	99.83	99.86	99.86	99.74
DBscan-TSVM-Train	99.83	98.14	98.80	99.63
KMC-SRC-Train	99.89	99.89	99.89	99.74
SC-SRC-Train	99.89	99.91	99.89	99.91
MSC-SRC-Train	99.89	99.08	98.80	99.83
Kmedoids-SRC-Train	99.89	99.89	99.74	99.77
DBscan-SRC-Train	99.89	99.66	99.37	99.86

5.16' da görülmektedir.

TSVM yapısı itibariyle az sayıdaki etiketli örneklerle başarılı çalıştığı gibi etiketli örnek sayısı arttıkça karmaşıklığı artması ve lokal optimumlara takılma gibi problemlerden

Tablo 5.11 Indian Pines verisi için farklı etiketli örnek sayıları için 5x5 pencere boyutu için eğitim kümesi sınıflama sonuçları (%)

5x5 Metotlar	1	3	5	15
KMC-SVM-Train	0.00	97.39	98.80	99.54
SC-SVM-Train	0.00	89.19	97.51	99.83
MSC-SVM-Train	0.00	89.48	78.21	93.12
Kmedoids-SVM-Train	0.00	95.56	96.76	99.28
DBscan-SVM-Train	0.00	72.79	86.84	94.49
KMC-TSVM-Train	100	100	100	100
SC-TSVM-Train	100	100	100	100
MSC-TSVM-Train	100	100	100	100
Kmedoids-TSVM-Train	100	100	100	100
DBscan-TSVM-Train	100	100	100	100
KMC-SRC-Train	100	100	100	100
SC-SRC-Train	100	100	100	100
MSC-SRC-Train	100	100	100	100
Kmedoids-SRC-Train	100	100	100	100
DBscan-SRC-Train	100	100	100	100

Tablo 5.12 Indian Pines verisi için farklı etiketli örnek sayıları için 7x7 pencere boyutu için eğitim kümesi sınıflama sonuçları (%)

7x7 Metotlar	1	3	5	15
KMC-SVM-Train	0.00	65.64	94.47	98.57
SC-SVM-Train	0.00	64.30	92.89	98.91
MSC-SVM-Train	0.00	57.39	72.24	96.65
Kmedoids-SVM-Train	0.00	77.12	82.28	99.11
DBscan-SVM-Train	0.00	55.87	63.69	96.82
KMC-TSVM-Train	99.80	99.83	99.80	99.89
SC-TSVM-Train	99.77	99.83	99.83	99.83
MSC-TSVM-Train	99.80	99.80	98.62	99.89
Kmedoids-TSVM-Train	99.80	99.83	99.83	99.89
DBscan-TSVM-Train	99.80	99.60	99.86	96.14
KMC-SRC-Train	99.89	99.86	99.83	99.89
SC-SRC-Train	99.89	99.89	99.86	99.86
MSC-SRC-Train	99.83	99.89	99.91	100
Kmedoids-SRC-Train	99.89	99.86	99.86	99.89
DBscan-SRC-Train	99.89	99.91	99.97	100

dolayı SVM ile karşılaştırıldığında zaman zaman başarıyı düşmektedir. Tablolarda her sınıftan bir etiketli veri ile TSVM ve S^3RC yöntemlerinin SVM' e görece çok daha başarılı olduğu görülmektedir. Diğer yandan etiketli örnek sayısı ile SVM yönteminin başarıyı kat ve kat artarken diğer yöntemlerin başarımları stabil kalmaktadır.

Tablo 5.13 Indian Pines verisi için farklı etiketli örnek sayıları için 1x1 pencere boyutu için tüm etiketsiz örneklerin sınıflama sonuçları (%)

1x1 Metotlar	1	3	5	15
KMC-SVM-Test	0.05	75.27	79.56	82.44
SC-SVM-Test	0.09	64.92	78.19	81.60
MSC-SVM-Test	0.05	45.90	56.10	79.12
Kmedoids-SVM-Test	0.05	75.29	78.37	84.27
DBscan-SVM-Test	0.05	45.72	44.54	70.58
KMC-TSVM-Test	83.02	87.19	88.51	87.97
SC-TSVM-Test	83.66	87.16	87.98	88.00
MSC-TSVM-Test	81.36	84.33	85.78	85.71
Kmedoids-TSVM-Test	83.02	87.36	87.52	87.28
DBscan-TSVM-Test	83.02	79.94	79.41	82.91
KMC-SRC-Test	87.94	87.72	88.47	88.58
SC-SRC-Test	86.65	87.71	88.74	88.59
MSC-SRC-Test	87.76	87.65	88.15	88.22
Kmedoids-SRC-Test	87.94	88.45	88.30	88.63
DBscan-SRC-Test	87.94	87.21	86.15	88.39

Tablo 5.14 Indian Pines verisi için farklı etiketli örnek sayıları için 3x3 pencere boyutu için tüm etiketsiz örneklerin sınıflama sonuçları (%)

3x3 Metotlar	1	3	5	15
KMC-SVM-Test	0.01	83.21	88.23	92.65
SC-SVM-Test	0.01	74.88	89.06	92.17
MSC-SVM-Test	0.00	58.57	72.75	84.89
Kmedoids-SVM-Test	0.01	85.21	89.00	93.00
DBscan-SVM-Test	0.01	53.24	64.96	79.93
KMC-TSVM-Test	94.48	94.89	94.63	94.38
SC-TSVM-Test	93.71	94.03	95.03	94.91
MSC-TSVM-Test	94.43	93.60	93.49	94.44
Kmedoids-TSVM-Test	94.48	94.63	94.63	94.25
DBscan-TSVM-Test	94.48	93.40	93.24	94.47
KMC-SRC-Test	95.63	95.63	95.63	95.56
SC-SRC-Test	95.63	95.63	95.62	95.63
MSC-SRC-Test	95.63	95.04	94.67	95.69
Kmedoids-SRC-Test	95.63	95.63	95.57	95.57
DBscan-SRC-Test	95.63	95.53	95.25	95.70

Pavia Üniversite verisinin aksine Indian Pines veri kümesinde en iyi sonuçlar 7x7 pencere boyutunda elde edilmiştir. Bu noktadan yola çıkarak farklı veri kümeleri için farklı pencere boyutlarının belirlenmesi gerektiği ortaya çıkmaktadır.

Tablo 5.15 Indian Pines verisi için farklı etiketli örnek sayıları için 5x5 pencere boyutu için tüm etiketsiz örneklerin sınıflama sonuçları (%)

5x5 Metotlar	1	3	5	15
KMC-SVM-Test	0.00	92.26	92.86	95.60
SC-SVM-Test	0.00	79.72	92.13	95.61
MSC-SVM-Test	0.00	80.18	70.41	85.81
Kmedoids-SVM-Test	0.00	89.96	89.97	92.74
DBscan-SVM-Test	0.00	64.91	78.76	84.91
KMC-TSVM-Test	96.29	96.29	96.29	96.29
SC-TSVM-Test	96.29	96.29	96.29	96.29
MSC-TSVM-Test	96.29	96.29	96.29	96.29
Kmedoids-TSVM-Test	96.29	96.29	96.29	96.29
DBscan-TSVM-Test	96.29	96.29	96.29	96.29
KMC-SRC-Test	97.32	97.32	97.32	97.32
SC-SRC-Test	97.32	97.32	97.32	97.32
MSC-SRC-Test	97.32	97.32	97.32	97.32
Kmedoids-SRC-Test	97.32	97.32	97.32	97.32
DBscan-SRC-Test	97.32	97.32	97.32	97.32

Tablo 5.16 Indian Pines verisi için farklı etiketli örnek sayıları için 7x7 pencere boyutu için tüm etiketsiz örneklerin sınıflama sonuçları (%)

7x7 Metotlar	1	3	5	15
KMC-SVM-Test	0.00	57.48	86.20	92.81
SC-SVM-Test	0.00	56.85	82.78	92.83
MSC-SVM-Test	0.00	50.93	63.97	90.22
Kmedoids-SVM-Test	0.00	69.36	72.74	94.23
DBscan-SVM-Test	0.00	49.88	57.32	90.08
KMC-TSVM-Test	96.55	96.75	96.55	96.39
SC-TSVM-Test	96.20	96.75	96.74	96.74
MSC-TSVM-Test	96.55	96.59	95.00	96.34
Kmedoids-TSVM-Test	96.55	96.29	96.74	96.39
DBscan-TSVM-Test	96.55	95.47	96.33	96.14
KMC-SRC-Test	97.70	97.93	97.93	97.86
SC-SRC-Test	97.70	97.91	97.91	97.94
MSC-SRC-Test	97.93	97.91	97.85	97.71
Kmedoids-SRC-Test	97.70	97.93	97.91	97.94
DBscan-SRC-Test	97.70	97.85	97.74	97.71

Tüm tablolar incelendiğinde spektral bilginin yanında uzamsal bilginin kullanımının sınıflama başarımına etkisinin olduğu görülmektedir. Her veri kümesi için optimum pencere boyutunun farklı olduğu gözlemlenmiştir. Ayrıca tüm pencere boyutları için bir etiketli örnekle sadece TSVM ve S^3RC yöntemleri başarılı sonuçlar vermektedir.

Bunun nedeni SVM yönteminin etiketsiz veri bilgilerini kullanmaması ve model eğitimi için çok düşük sayıdaki etiketli verinin yetersiz olmasıdır. S^3RC yönteminin genel olarak TSVM’ den daha başarılı sonuçlar elde etmesinin sebebi ise gürültüye ve hatalı etiket bilgisine daha dayanıklı olmasıdır.

$$\text{Sensitivity (Duyarlılık)} = \frac{\text{Doğru Pozitif Etiketlemeler}}{\text{Tüm Pozitif Örnekler}} \quad (5.4)$$

$$\text{Specificity (Özgüllük)} = \frac{\text{Doğru Negatif Etiketlemeler}}{\text{Tüm Negatif Örnekler}} \quad (5.5)$$

$$\text{Precision (Kesinlik)} = \frac{\text{Doğru Pozitif Etiketlemeler}}{\text{Tüm Etiketlemeler}} \quad (5.6)$$

$$\text{F1-score} = \frac{2 * \text{precision} * \text{recall}}{\text{precision} + \text{recall}} \quad (5.7)$$

$$\text{Kappa Değeri} = \frac{\text{gözlem doğruluğu} - \text{tahmin doğruluğu}}{1 - \text{tahmin doğruluğu}} \quad (5.8)$$

Diğer makine öğrenmesiyle sınıflama alanlarında olduğu gibi hiperspektral görüntülerin sınıflandırılmasında da sınıflama başarımının ölçümünde doğruluk (accuracy) dışında farklı değerlendirme kriterleri de bulunmaktadır. Bunlar sensitivity (duyarlılık), specificity (özgüllük), F1-skoru ve kappa değeridir. Sensitivity değeri (5.4) eşitliğince hesaplanır ve pozitif örneklerin ne kadarının doğru sınıflandığını ölçer. Specificity değeri ise (5.5) eşitliğince hesaplanır ve negatif örneklerin ne kadar doğru sınıflandığını ölçer. F1-skoru hesaplanırken precision (kesinlik) ve recall (hassasiyet) kavramları karşımıza çıkmaktadır. Precision kavramı doğru etiketlemelerin tüm etiketlemelere oranlaması ile bulunur ve (5.6) eşitliğince hesaplanır. Recall değeri ise specificity ile aynı değeri ifade etmektedir ve (5.4) eşitliğince hesaplanır. Buradan yola çıkarak F1-skoru (5.7) eşitliğince hesaplanmaktadır. Kappa değeri ise (5.8) eşitliğince hesaplanır. Sınıflama başarımı dışında elde edilen sonuçların istatistiksel olarak anlamlı olduğunun gösterilmesi amacıyla Tablo A.1’ de Pavia Üniversite veri kümesiyle SVM ve TSVM, Tablo A.2’ de Indian Pines veri kümesiyle SVM ve TSVM, Tablo A.3’ de Pavia Üniversite veri kümesiyle S^3RC ve Tablo A.4’ de Indian Pines veri kümesiyle S^3RC ile elde edilen sınıflama sonuçlarının doğruluk, duyarlılık, özgüllük, F1-skorları ve kappa değerleri hesaplanarak sunulmuştur. Tablolarda k-ortalamlar kümeleme, ortalama-kaydırma kümeleme, eksiltici kümeleme, k-medoid kümeleme ve db-scan kümeleme yöntemleriyle elde edilen sonuçlar ayrı ayrı sunulmuştur. Ayrıca tablolarda

sınıf bazında başarımlar oranları farklı pencere boyutları için hesaplanmıştır. Aynı sınıf başarımlarını hesaplanmasının temel nedeni, sınıflama başarımının sınıf bazında büyük farklılıklar gösterip göstermediğini gözlemlemektir.

5.4 Sonuç ve Öneriler

Veri etiketlemenin/yer-gerçekliği oluşturma zorluğu ve maliyeti diğer alanlarda olduğu gibi hiperspektral görüntülemenin de en önemli problemlerinden biridir. Etiketli verinin oluşturulması zorluğu, az etiketli veri ile yüksek sınıflama başarımlarını yakalama problemini ortaya çıkarmaktadır. Bunun için ortaya koyulan pek çok yarı-güdümlü öğrenme yöntemi bulunmaktadır. Hangisinin daha iyi sonuç verdiği kullanılan veriden veriye değişmektedir. Ayrıca verinin lineer olarak ayrılıp ayrılamaması da temel problemlerden biridir. Bu çalışmada verinin derin öğrenme modelleriyle farklı bir uzaya taşınması sayesinde ayrıştırılabilirliği artırılmıştır. Ayrıca veri boyutu önemli ölçüde düşürülmüştür.

Yapılan çalışmada son yıllarda revaçta olan derin öğrenmenin yarı-güdümlü öğrenme ve hiperspektral görüntü işleme nasıl uygulanacağına dair örnek ortaya konulmuştur. Ayrıca aynı sensörler ile alınan farklı veri kümeleri için genel bir öznetelik çıkarıcı ve boyut indirgeyici bir model sunulmuştur. Veri kümelerinin temel karakteristikleri benzer olduğunda ortak model kullanılabileceği veya modelde ufak ince ayarlamalar yapılarak aynı modelin kullanılabileceği kanıtlanmıştır. Farklı ve aynı temellere dayanan kümeleme yöntemleri kullanılmış, yarı-güdümlü ve güdümlü öğrenme başarımına etkisi araştırılmıştır.

Yarı-güdümlü öğrenme yöntemlerinden biri olan TSVM' in beklenildiği şekilde çok küçük etiketli örnek sayılarında çok başarılı bir şekilde çalıştığı fakat bazı durumlarda eğitim örnekleriyle lokal optimumlara takıldığı gözlemlenmiştir. Ayrıca bazı durumlarda TSVM' in optimize olamadığı için çalışması süresinin uzadığı deneyimlenmiştir. SVM algoritmasının büyük etiketli örnek sayılarında yukarıda TSVM' in dezavantajları olarak bahsedebileceğimiz durumlardan dolayı yarı-güdümlü versiyonundan daha başarılı bir şekilde çalıştığı görülmüştür. Sözlük tabanlı bir sınıflama yöntemi olan SRC bu çalışmada iteratif self-training(kendi kendine öğrenme) yöntemiyle yarı-güdümlü hale getirilmiştir. Bu sayede gürültüye ve yanlış etiket bilgisine dayanıklı olan bir yöntem yarı-güdümlü öğrenmede kullanılabilir hale gelmiştir. Buna imkân sağlayan temel nokta ise derin öğrenme ile çıkarılan düşük boyutlu lineer ayrılabilir özneteliklerdir. Derin öğrenme modelleri ile öznetelik çıkarımı gerçekleştirilmemiş olması durumunda lineer yerine daha çok işlem maliyeti gerektiren kernel (çekirdek) SRC kullanımı gereklilik kazanacaktı. Ayrıca bir yakınsama

problemi olan TSVM ve SRC yöntemleri, öznitelik boyutu yüksek olan problemlerde işlem maliyetinden dolayı kullanılabilir değildir.

Yapılan çalışmalarda parametre optimizasyonu süre darlığından dolayı tam manasıyla gerçekleştirilememiştir. SVM, TSVM ve S^3RC parametrelerindeki optimizasyonların başarımı arttırması olasıdır. Ayrıca farklı kümeleme yöntemleriyle ilklendirmenin farklı durumlarda ve veri kümelerinde başarımı yükselteceği veya düşüreceği gözlemlenmiştir. Tüm pencere boyutları için elde edilen derin öğrenme modellerinin farklı verilerde öznitelik çıkarımı için kullanılması, hem yüksek boyuttan kaynaklanan hesaplama maliyetinden kurtulmayı hem de modelin veriyi lineer olarak ayrılabilen bir uzayda temsil etmesinden dolayı yüksek başarımla elde edilmesine olanak sağlayacaktır.

6 Sonuç ve Öneriler

Hiperspektral görüntülerde etiketli örnek zaman ve iş gücü açısından maliyetli olduğundan dolayı etiketli az ve sınırlı sayıdadır. Bunun yanında az olan etiketli örneklerde sadece saf piksellerden oluşmadığı, karışık pikselleri de içerdiği için az olan etiketli örneklerin arasında yanlış etiketlenmiş örneklerin olması da muhtemeldir. Hiperspektral görüntülerin analizinde az olan etiketli örneklerin kullanılarak tüm sahnenin veya sahnenin büyük bir bölümünün sınıflanması temel amaçlardandır. Geleneksel makine öğrenmesi yaklaşımlarında etiketleme yani literatürde kullanılan şekliyle sınıflama etiketli örnek sayısına ve etiketli örneklerin kalitesiyle doğru orantılıdır. Bu nedenle etiketli örnek sayısı az olan hiperspektral görüntülerin geleneksel yöntemlerle yüksek başarımda sınıflandırılması zor bir problemidir. Buradan yola çıkarak, bu tez çalışmasında hem etiketli hem de etiketsiz veri bilgilerinin beraber kullanılmasıyla son yıllarda ortaya çıkan yarı-güdümlü öğrenme yaklaşımları kullanılarak hiperspektral görüntülerin sınıflanması hedeflenmiştir. Tez çalışması kapsamında 3 farklı model ortaya koyulmuştur. Bunlardan ilki diğer yöntemlere görece daha basit olan artımsal olarak veri etiketlemeyi hedefleyen bir yapıdır. İkincisi graf tabanlı bir sistemdir. Üçüncüsü ise yapay sinir ağlarının gelişen teknoloji ve hesaplama gücüyle gelişmiş hali olan derin öğrenme tabanlı bir sistemdir.

Literatürde etiketli ve etiketsiz veri bilgilerinin kullanılmasına yönelik farklı yaklaşımlar bulunmaktadır. Kendi kendine eğitim temelli özyinelemeli yarı-güdümlü öğrenme yaklaşımlarında iki temel adım vardır. Bunlardan ilki etiketli örnek seçimi, ikincisi ise etiketsiz örneklerin etiketlenmesi işlemidir. Tez çalışmasında önerilen tüm yöntemlerde temel olarak bu iki temel adım göz önünde bulundurularak sistem çerçeveleri oluşturulmuştur. Her sistemde öncelikle en çok bilgi sağlayacak etiketli örneklerin seçilmesi hedeflenmiştir. Ardından etiketsiz örneklerin doğru etiketlenmesi temel ilke olarak göz önünde bulundurulmuştur. Etiketsiz örneklerin etiketlenmesi aşamasında farklı yaklaşımlar uygulanmıştır. Hesaplama maliyetinden dolayı önerilen yapılarda sadece etiketsiz eğitim örneklerinin yarı-güdümlü olarak etiketlenmesi veya daha düşük hesaplama maliyetine sahip yapılarda etiketsiz

olan hem eğitim hem de test örneklerinin sınıflandırılması gibi farklı kullanımlara gidilmiştir.

Önerilen yöntemlerden ilki yarı-güdümlü öğrenme yöntemlerinden anlaşılabilirliği en kolay olan kendi kendine eğitim yöntemini temel alan artımsal modeldir. Burada yukarıda bahsedilen yarı-güdümlü öğrenme yöntemlerinin temel adımlarından olan en çok bilgi sağlayacak etiketli örneklerin seçimi için kümeleme yöntemleri kullanılmıştır. Literatürde iyi bilinen kümeleme yöntemlerinden k-ortalamlar kümeleme yöntemi seçilerek ilk deneysel çalışmalar gerçekleştirilmiştir. Yine bir kümeleme yöntemi olan ve yarı-güdümlü öğrenme literatüründe daha önce kullanılmamış olan eksiltici kümeleme etiketli örnek seçimi için ikinci kümeleme yöntemi olarak kullanılmıştır. Seçilen etiketli örnekler en yakın etiketsiz eğitim örneği etiketlenerek etiketli örnek kümesine katılır ve diğer etiketsiz eğitim örneklerinin etiketlenmesi etiketsiz eğitim örneği kalmayınca kadar devam edilir. Eğitim örneklerinin etiketlenmesi tamamlandığında test örnekleri 2 farklı yöntemle sınıflandırılır. Bunlardan ilki hiperspektral görüntü analizinde sıkça kullanılan destek vektör makineleridir. İkincisi ise seyrek gösterim sınıflayıcısıdır. Bu iki sınıflandırıcı sonucunun karar seviyesinde birleştirilmesiyle nihai sistem başarımı hesaplanmıştır. Burada iki sınıflandırıcı sonucunun birleştirilmesiyle elde edilebilecek maksimum sistem başarımı ve hali hazırda kullanılan birleştirme yöntemiyle elde edilen sistem başarımı karşılaştırılarak birleştirme yönteminin optimize hale getirilmesi temel odak noktasıdır. Ayrıca ilklendirme aşamasındaki etiketli örnek sayısı değiştirilerek etiketli örnek sayısının sistem başarısına etkisi araştırılmıştır. Bunun yanında bu aşamada herhangi uzamsal bilgi kullanılmamıştır, yapılan işlemler özyinelemeli olarak tekrarlandığı için kullanılacak uzamsal bilgi işlem maliyetini artıracığı için sistem piksel vektörleri üzerine kurgulanmıştır. Bunun yanında bant seçiminin ve bağımsız bileşen analizinin sistem üzerindeki etkisi gözlemlenmiştir.

İkinci olarak önerilen sistem graf tabanlı bir yapıya sahiptir. Temel olarak artımsal model ile benzerlik gösterse de hesaplama maliyetinin düşürülmesi ve grafik işleme ünitesine aktarılan hesaplamalar ile uzamsal bilginin kullanılması sayesinde daha fazla hareket alanı oluşturulmuştur. Graf tabanlı sistemde yarı-güdümlü öğrenme aşaması bir graf üzerinde gerçekleştirilmektedir. Tüm eğitim kümesi veya elimizdeki bütün veriler bir graf üzerine yerleştirilerek tüm örneklerin birbiriyle olan ilişki grafi çıkarılır. Ardından bu graf üzerinde etiketli örnek seçimi yapılır ve etiketsiz örneklerin etiketlenmesi graf üzerindeki ilişkileri üzerinden gerçekleştirilir. Burada eğitim ve test kümesinin olmak üzere tüm etiketsiz örneklerin graf üzerinden etiketlenmesi de gerçekleştirilmiştir. Ayrıca bu yapıda komşuluk pikseller de işin içine katılarak uzamsal bilginin kullanılması da sağlanmıştır. Test kümesinin sınıflanmasında daha önceki bölümlerde anlatılan çekirdek destek vektör makineleri ve çekirdek seyrek

gösterim sınıflayıcısının yanında son yıllarda revaçta olan bir makine öğrenmesi yöntemi olan derin öğrenme yaklaşımı ile de sınıflama gerçekleştirilmiştir. Burada kullanılan derin öğrenme modeller daha önce literatürde nesne tanıma için kullanılmış önceden eğitilmiş modellerinin üzerine eğitim yapılarak oluşturulmuştur. Yine karar seviyesinde sınıflama sonuçları birleştirilmiştir. Diğer iki sınıflayıcı sonuçlarının yanı sıra karar seviyesinde derin öğrenme modelinin sonuçları ile de birleştirme yapılarak sonuçlar gözlenmiştir.

Tez çalışmasının beşinci bölümünde üçüncü sistem olarak derin öğrenme tabanlı bir sistem önerilmiştir. Tez çalışmasının bu bölümünde hem hazır derin öğrenme modelleri hem de yeni derin öğrenme yapıları ortaya koyulmuştur ve sistem başarımları gözlenmiştir. Hazır modellerin gereksiz işlem maliyeti oluşturmamasından ve yeteri kadar veriyle beslenememesi gibi sebeplerden dolayı özgün derin modeller oluşturulmuştur. Önerilen sistem hiperspektral görüntülerin derin ağlara girdi olabilmesi için yeni bir veri dönüşümü önerilmiştir. Ayrıca hiperspektral görüntülerde ince-ayar (fine-tuning) çalışması gerçekleştirilmiştir. Sistem sayesinde her veri kümesi için bir model eğitilmesi yerine aynı özelliklerde veri kümeleri için tek bir genel model oluşturulması ve bu modelin üzerinde ince-ayar yapılması önerilmiştir. İnce ayarla elde edilen modeller lineer olarak ayrılabilen, düşük vektör boyutundan dolayı düşük hesaplama maliyeti gerektiren öznitelik vektörleri elde edilmiştir. Bu sayede daha önce kullanılamayan bazı yöntemler kullanılmıştır. Literatür yarı-güdümlü destek vektör makineleri veya transdüktif destek vektör makineleri (transductive support vector machines) kullanılmıştır. Ayrıca önerilen sistem sayesinde yeni bir yarı-güdümlü seyrek gösterim sınıflayıcısı sunulmuştur. Önerilen sistem yapısıyla elde edilen sonuçlar detaylı bir şekilde incelenmiş ve en gelişkin (state of the art) çalışmalar ile genel kullanıma açık veri kümeleri üzerinde karşılaştırma yapılmıştır. Bunun yanında önerilen sistemin çok az etiketli veri ile kabul edilebilir başarımlar değerlerine ulaşabildiği gözlemlenmiştir. Önerilen sistemde etiketli örnek seçimi 5 farklı kümeleme yöntemi ile gerçekleştirilmiştir. Bunun temel nedeni farklı yapıya sahip kümeleme yöntemlerinin sistemi nasıl etkilediği ve sistemin gürbüzlüğünün gözlemlenmesidir.

Yarı-güdümlü öğrenme yöntemleri hem etiketli hem de etiketsiz verideki bilgi kullanarak hedeflerine ulaşmayı hedeflemektedirler. Veri etiketlemenin zaman ve iş gücü maliyetinden dolayı az sayıdaki etiketli örnek hiperspektral veri analizi araştırmacılar için temel amaç haline gelmiştir. Bu tez çalışmasında da yarı-güdümlü öğrenme yöntemleri kullanılarak hiperspektral görüntülerin sınıflanması amaçlanmıştır. Elde edilen sonuçlar literatürdeki çalışmalar ile karşılaştırılmış ve önerilen sistemin başarısının ve kullanılabilirliğinin amaçlanan düzeyde olduğu görülmüştür.

A

Detaylı Sınıflama Sonuçları

Tablo A.1 Pavia Üniversite veri kümesi için farklı etiketli örnek sayıları ve farklı pencere boyutları için tüm etiketsiz örneklerin SVM ve TSVM ile detaylı sınıflama sonuçları

Clustering_Name: KMEANS; Window_Size_1; Selected_Sample_Number_perClass_1									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	0.084	0.001	0.876	NaN	-0.013				
TSVM	79.348	0.79	0.971	0.791	0.757				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	0.014	0	0	0.948	0.311	0	0	0	0
TSVM	73.186	82.495	63.107	70.736	99.006	70.077	97.771	84.009	99.83
Clustering_Name: KMEANS; Window_Size_1; Selected_Sample_Number_perClass_3									
	Acc.	Sens.	Spec.	F1score	Kappa				

SVM	80.322	0.852	0.972	0.801	0.766				
TSVM	84.596	0.848	0.978	0.851	0.816				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	75.01	85.486	70.012	45.011	77.764	78.061	93.724	95.138	99.915
TSVM	77.518	83.824	73.304	74.47	98.82	92.447	96.246	90.729	99.83
Clustering_Name: KMEANS; Window_Size_1; Selected_Sample_Number_perClass_5									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	82.616	0.844	0.975	0.814	0.793				
TSVM	83.569	0.814	0.976	0.824	0.805				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	85.137	83.308	64.593	53.149	77.826	89.822	94.956	93.47	99.83
TSVM	71.291	83.376	67.925	79.376	98.385	91.8	97.243	91.611	99.83
Clustering_Name: KMEANS; Window_Size_1; Selected_Sample_Number_perClass_15									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	83.314	0.863	0.975	0.855	0.804				
TSVM	84.127	0.833	0.977	0.845	0.813				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	87.798	77.69	78.001	71.07	90.807	93.041	93.959	90.253	99.83

TSVM	81.39	80.546	76.074	83.974	99.068	93.203	96.364	85.987	89.049
Clustering_Name: KMEANS; Window_Size_1; Selected_Sample_Number_perClass_30									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	85.819	0.871	0.979	0.869	0.83				
TSVM	84.971	0.843	0.978	0.858	0.822				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	87.018	84.064	72.381	76.421	95.714	90.793	95.191	89.8	99.406
TSVM	83.368	81.401	77.318	83.528	99.441	92.322	96.07	86.058	99.066
Clustering_Name: KMEANS; Window_Size_3; Selected_Sample_Number_perClass_1									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	0.002	0.111	0.783	NaN	-0.004				
TSVM	91.492	0.928	0.987	0.92	0.895				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	0.014	0	0	0	0.062	0	0	0	0
TSVM	89.971	91.38	74.669	88.211	99.627	93.94	93.548	97.974	99.406
Clustering_Name: KMEANS; Window_Size_3; Selected_Sample_Number_perClass_3									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	86.089	0.9	0.98	0.852	0.831				
TSVM	90.051	0.917	0.985	0.916	0.879				

[illegible]

	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	88.038	0.91	0.982	0.907	0.857				
TSVM	90.194	0.911	0.985	0.917	0.881				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	90.166	81.651	81.172	85.452	99.13	97.375	95.894	97.045	98.812
TSVM	89.609	85.169	80.731	95.151	99.317	97.878	97.009	96.759	98.557
Clustering_Name: KMEANS; Window_Size_5; Selected_Sample_Number_perClass_1									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	0.107	0.111	0.782	NaN	-0.002				
TSVM	90.008	0.908	0.985	0.906	0.878				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	0.014	0	0	0	3.106	0	0	0	0
TSVM	77.211	89.76	80.931	95.429	95.901	97.267	95.953	97.807	96.01
Clustering_Name: KMEANS; Window_Size_5; Selected_Sample_Number_perClass_3									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	84.091	0.888	0.977	0.846	0.81				
TSVM	92.13	0.919	0.989	0.918	0.902				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9

SVM	78.145	84.976	75.311	68.701	74.969	89.103	93.372	98.665	94.822
TSVM	83.187	93.397	80.329	96.656	95.28	94.677	96.54	97.831	94.143
Clustering_Name: KMEANS; Window_Size_5; Selected_Sample_Number_perClass_5									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	92.023	0.908	0.989	0.905	0.9				
TSVM	91.745	0.914	0.988	0.914	0.898				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	85.973	95.435	80.128	86.929	94.037	91.135	91.73	97.355	96.859
TSVM	84.343	91.891	80.289	96.711	93.043	95.828	97.185	97.521	94.058
Clustering_Name: KMEANS; Window_Size_5; Selected_Sample_Number_perClass_15									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	91.458	0.918	0.988	0.911	0.894				
TSVM	92.218	0.923	0.989	0.922	0.904				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	85.388	93.152	80.65	86.957	95.652	93.275	93.196	98.499	95.501
TSVM	86.057	92.292	80.931	96.46	96.273	95.738	95.718	97.283	94.228
Clustering_Name: KMEANS; Window_Size_5; Selected_Sample_Number_perClass_30									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	84.838	0.89	0.977	0.886	0.822				

TSVM	92.218	0.923	0.989	0.922	0.904				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	85.179	75.976	82.537	91.555	94.099	94.264	97.126	96.33	95.671
TSVM	86.057	92.292	80.931	96.46	96.273	95.738	95.718	97.283	94.228
Clustering_Name: KMEANS; Window_Size_7; Selected_Sample_Number_perClass_1									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	0.156	0.111	0.782	NaN	-0.003				
TSVM	89.201	0.914	0.986	0.89	0.865				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	0.014	0	0	0	4.534	0	0	0	0
TSVM	75.428	98.312	80.65	96.21	89.379	67.47	93.842	94.924	96.689
Clustering_Name: KMEANS; Window_Size_7; Selected_Sample_Number_perClass_3									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	88.697	0.933	0.986	0.88	0.858				
TSVM	92.276	0.924	0.989	0.915	0.903				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	88.132	99.609	77.68	61.706	90.683	66.373	88.563	96.425	95.246
TSVM	86.126	95.758	78.121	96.377	90.062	87.898	93.548	96.64	96.774

[illegible]

Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	84.998	96.534	78.764	93.144	94.161	89.462	92.786	96.497	97.199
TSVM	85.848	96.394	78.844	96.516	94.161	85.74	93.021	96.235	96.689
Clustering_Name: MEANSHIFT; Window_Size_1; Selected_Sample_Number_perClass_1									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	0.036	0.001	0.862	NaN	-0.009				
TSVM	83.436	0.828	0.976	0.83	0.803				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	0.014	0	0	0.279	0.435	0	0	0	0
TSVM	78.59	83.214	65.516	73.634	98.882	91.674	97.009	84.795	99.83
Clustering_Name: MEANSHIFT; Window_Size_1; Selected_Sample_Number_perClass_3									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	68.73	0.778	0.958	0.632	0.645				
TSVM	81.98	0.823	0.974	0.809	0.786				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	50.801	73.584	0.442	47.352	88.82	76.659	98.944	96.759	100
TSVM	69.815	85.622	63.749	74.443	98.385	84.967	97.771	84.867	88.625
Clustering_Name: MEANSHIFT; Window_Size_1; Selected_Sample_Number_perClass_5									
	Acc.	Sens.	Spec.	F1score	Kappa				

SVM	72.722	0.795	0.962	0.783	0.698				
TSVM	76.208	0.808	0.966	0.792	0.73				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	77.365	57.429	70.695	70.095	98.571	93.311	97.478	83.294	99.83
TSVM	73.645	68.185	67.202	71.488	99.379	91.872	98.123	85.057	87.097
Clustering_Name: MEANSHIFT; Window_Size_1; Selected_Sample_Number_perClass_15									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	75.763	0.781	0.965	0.775	0.722				
TSVM	79.65	0.8	0.971	0.803	0.765				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	59.59	74.214	77.64	64.688	98.944	83.151	98.006	84.366	99.915
TSVM	69.815	75.371	72.902	81.717	98.323	89.426	98.475	87.417	90.662
Clustering_Name: MEANSHIFT; Window_Size_1; Selected_Sample_Number_perClass_30									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	81.406	0.801	0.973	0.815	0.778				
TSVM	83.204	0.818	0.975	0.834	0.802				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	77.713	85.95	88.398	81.884	99.193	64.179	96.246	67.207	99.745

TSVM	75.247	81.354	70.574	85.006	99.255	87.125	97.361	89.514	99.66
Clustering_Name: MEANSHIFT; Window_Size_3; Selected_Sample_Number_perClass_1									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	0.021	0.111	0.788	NaN	-0.001				
TSVM	89.847	0.918	0.985	0.913	0.877				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	0.014	0	0	0	0.621	0	0	0	0
TSVM	90.124	85.862	73.946	89.883	99.689	97.698	94.663	98.213	99.321
Clustering_Name: MEANSHIFT; Window_Size_3; Selected_Sample_Number_perClass_3									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	86.901	0.915	0.984	0.842	0.836				
TSVM	90.136	0.921	0.985	0.915	0.88				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	90.403	98.103	55.761	32.274	99.379	75.508	96.833	97.855	98.642
TSVM	95.278	85.398	72.381	90.747	99.193	97.536	95.543	95.281	98.217
Clustering_Name: MEANSHIFT; Window_Size_3; Selected_Sample_Number_perClass_5									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	85.995	0.897	0.983	0.833	0.825				
TSVM	91.903	0.928	0.988	0.922	0.9				

[illegible]

	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	0.107	0.111	0.782	NaN	-0.002				
TSVM	90.8	0.917	0.987	0.912	0.886				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	0.014	0	0	0	3.106	0	0	0	0
TSVM	78.535	92.537	79.888	96.21	95.963	93.976	94.604	96.425	96.265
Clustering_Name: MEANSHIFT; Window_Size_5; Selected_Sample_Number_perClass_3									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	82.521	0.845	0.977	0.768	0.788				
TSVM	91.948	0.897	0.988	0.907	0.9				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	75.498	90.802	75.472	67.475	97.329	70.635	39.472	96.449	99.745
TSVM	85.054	92.662	80.209	93.283	96.335	94.803	96.657	97.569	96.774
Clustering_Name: MEANSHIFT; Window_Size_5; Selected_Sample_Number_perClass_5									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	86.468	0.857	0.981	0.836	0.834				
TSVM	90.031	0.869	0.985	0.885	0.878				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9

SVM	73.701	92.225	76.435	53.54	95.901	92.106	97.067	97.045	99.491
TSVM	78.284	90.015	80.851	93.506	96.957	96.673	93.959	97.593	97.284
Clustering_Name: MEANSHIFT; Window_Size_5; Selected_Sample_Number_perClass_15									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	91.248	0.895	0.987	0.906	0.892				
TSVM	92.218	0.923	0.989	0.922	0.904				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	81.947	90.739	81.574	97.213	95.28	96.637	97.185	97.355	97.199
TSVM	86.057	92.292	80.931	96.46	96.273	95.738	95.718	97.283	94.228
Clustering_Name: MEANSHIFT; Window_Size_5; Selected_Sample_Number_perClass_30									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	92.145	0.922	0.988	0.92	0.903				
TSVM	92.218	0.923	0.989	0.922	0.904				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	86.098	92.308	80.931	96.516	93.665	95.738	95.718	97.283	94.228
TSVM	86.057	92.292	80.931	96.46	96.273	95.738	95.718	97.283	94.228
Clustering_Name: MEANSHIFT; Window_Size_7; Selected_Sample_Number_perClass_1									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	0.152	0.111	0.782	NaN	-0.004				

TSVM	92.567	0.923	0.99	0.915	0.907				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	0.014	0	0	0	Nis.41	0	0	0	0
TSVM	88.815	95.857	78.121	96.433	90.062	87.844	91.144	95.853	96.689
Clustering_Name: MEANSHIFT; Window_Size_7; Selected_Sample_Number_perClass_3									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	86.355	0.874	0.983	0.831	0.83				
TSVM	92.37	0.926	0.99	0.918	0.904				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	76.125	98.754	73.745	53.79	90.87	69.268	93.783	97.14	97.878
TSVM	85.848	96.394	78.844	96.516	94.161	85.74	93.021	96.235	96.689
Clustering_Name: MEANSHIFT; Window_Size_7; Selected_Sample_Number_perClass_5									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	88.171	0.923	0.985	0.885	0.852				
TSVM	90.914	0.926	0.988	0.908	0.886				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	78.604	97.999	78.202	72.046	91.242	71.444	94.252	95.543	96.265
TSVM	85.416	97.816	79.085	96.488	95.59	68.567	93.021	96.235	97.114

[illegible]

Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	0.014	0	0	0.279	0.435	0	0	0	0
TSVM	52.264	69.962	69.169	75.251	95.839	91.153	91.554	83.651	97.284
Clustering_Name: SUBTRACT; Window_Size_1; Selected_Sample_Number_perClass_3									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	79.211	0.839	0.971	0.758	0.753				
TSVM	83.204	0.827	0.976	0.833	0.801				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	83.786	84.627	81.574	36.622	41.491	90.146	82.287	74.881	98.727
TSVM	77.044	83.027	84.384	71.99	97.391	93.67	96.54	74.023	99.915
Clustering_Name: SUBTRACT; Window_Size_1; Selected_Sample_Number_perClass_5									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	83.446	0.873	0.976	0.834	0.803				
TSVM	85.19	0.842	0.978	0.853	0.824				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	91.308	82.063	57.527	62.542	78.075	92.519	91.613	91.754	99.66
TSVM	85.193	82.443	68.968	82.219	97.391	92.052	95.601	87.798	99.83
Clustering_Name: SUBTRACT; Window_Size_1; Selected_Sample_Number_perClass_15									
	Acc.	Sens.	Spec.	F1score	Kappa				

SVM	86.973	0.881	0.981	0.874	0.843				
TSVM	85.1	0.853	0.978	0.858	0.823				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	89.358	85.867	66.399	77.341	97.019	92.519	93.079	91.111	99.83
TSVM	83.452	82.344	76.716	81.912	98.571	91.908	95.836	88.608	88.879
Clustering_Name: SUBTRACT; Window_Size_1; Selected_Sample_Number_perClass_30									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	87.297	0.87	0.981	0.873	0.846				
TSVM	85.815	0.858	0.979	0.862	0.83				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	88.341	87.545	79.165	77.313	92.05	88.743	93.372	88.012	99.83
TSVM	86.419	83.762	74.99	83.138	98.82	90.487	96.012	87.083	87.521
Clustering_Name: SUBTRACT; Window_Size_3; Selected_Sample_Number_perClass_1									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	0.009	0.111	0.786	NaN	-0.002				
TSVM	88.813	0.912	0.983	0.905	0.865				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	0.014	0	0	0	0.248	0	0	0	0

TSVM	85.82	84.767	69.008	93.98	98.758	97.752	95.308	98.522	99.321
Clustering_Name: SUBTRACT; Window_Size_3; Selected_Sample_Number_perClass_3									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	85.318	0.922	0.982	0.847	0.817				
TSVM	91.62	0.926	0.987	0.924	0.897				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	89.971	98.186	72.822	39.855	96.708	51.214	93.783	98.713	97.708
TSVM	88.313	90.661	79.125	91.109	99.814	95.9	95.132	97.164	99.151
Clustering_Name: SUBTRACT; Window_Size_3; Selected_Sample_Number_perClass_5									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	85.228	0.883	0.979	0.824	0.82				
TSVM	90.166	0.918	0.985	0.918	0.881				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	87.937	88.764	63.589	37.876	71.056	97.86	95.484	98.594	98.387
TSVM	91.071	85.143	79.727	93.032	98.447	98.22	94.252	97.307	99.151
Clustering_Name: SUBTRACT; Window_Size_3; Selected_Sample_Number_perClass_15									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	91.545	0.931	0.988	0.915	0.895				
TSVM	90.34	0.919	0.985	0.918	0.883				

Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	90.138	93.543	78.563	72.436	99.193	96.439	91.965	97.331	98.472
TSVM	90.612	85.7	77.479	93.813	99.503	98.13	94.252	97.831	99.236
Clustering_Name: SUBTRACT; Window_Size_3; Selected_Sample_Number_perClass_30									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	92.421	0.927	0.989	0.92	0.906				
TSVM	91.796	0.924	0.987	0.925	0.899				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	88.216	93.997	75.873	87.207	97.888	95.666	94.545	97.831	98.132
TSVM	92.06	88.832	79.004	94.008	98.571	97.59	94.428	97.307	98.727
Clustering_Name: SUBTRACT; Window_Size_5; Selected_Sample_Number_perClass_1									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	0.071	0	0.782	NaN	-0.01				
TSVM	89.168	0.901	0.984	0.899	0.868				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	0.014	0	0	0	5/2/01	0	0	0	0
TSVM	75.763	88.103	78.202	96.851	95.839	97.806	96.305	98.117	95.925
Clustering_Name: SUBTRACT; Window_Size_5; Selected_Sample_Number_perClass_3									

	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	87.19	0.92	0.983	0.863	0.841				
TSVM	92.13	0.919	0.989	0.918	0.902				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	85.123	96.42	68.005	66.499	92.671	68.819	83.519	99.762	92.784
TSVM	83.187	93.397	80.329	96.656	95.28	94.677	96.54	97.831	94.143
Clustering_Name: SUBTRACT; Window_Size_5; Selected_Sample_Number_perClass_5									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	88.974	0.917	0.985	0.879	0.863				
TSVM	92.231	0.92	0.989	0.92	0.904				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	86.851	94.711	69.129	67.28	87.391	89.265	89.677	95.52	92.954
TSVM	83.675	93.345	81.453	96.711	95.901	94.695	96.481	97.402	94.143
Clustering_Name: SUBTRACT; Window_Size_5; Selected_Sample_Number_perClass_15									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	90.95	0.921	0.986	0.914	0.889				
TSVM	92.218	0.923	0.989	0.922	0.904				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9

SVM	90.263	88.311	80.53	94.482	93.727	98.058	89.267	97.045	92.784
TSVM	86.057	92.292	80.931	96.46	96.273	95.738	95.718	97.283	94.228
Clustering_Name: SUBTRACT; Window_Size_5; Selected_Sample_Number_perClass_30									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	90.126	0.919	0.985	0.908	0.88				
TSVM	90.749	0.897	0.986	0.904	0.887				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	89.107	87.399	75.913	92.113	96.894	98.256	89.091	97.378	92.784
TSVM	80.624	90.25	82.617	96.711	95.714	97.033	95.191	96.997	94.482
Clustering_Name: SUBTRACT; Window_Size_7; Selected_Sample_Number_perClass_1									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	0.208	0.111	0.782	NaN	-0.002				
TSVM	89.477	0.919	0.986	0.894	0.868				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	0.014	0	0	0	6.025	0	0	0	0
TSVM	77.253	98.072	77.599	96.21	86.957	69.933	92.082	96.187	96.604
Clustering_Name: SUBTRACT; Window_Size_7; Selected_Sample_Number_perClass_3									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	89.663	0.916	0.987	0.89	0.871				

TSVM	92.276	0.924	0.989	0.915	0.903				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	72.085	97.301	77.84	91.611	85.466	84.014	92.786	96.354	95.501
TSVM	86.126	95.758	78.121	96.377	90.062	87.898	93.548	96.64	96.774
Clustering_Name: SUBTRACT; Window_Size_7; Selected_Sample_Number_perClass_5									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	87.136	0.901	0.982	0.871	0.843				
TSVM	92.276	0.924	0.989	0.915	0.903				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	71.236	90.328	74.187	86.315	77.143	94.282	91.789	98.117	96.01
TSVM	86.126	95.758	78.121	96.377	90.062	87.898	93.548	96.64	96.774
Clustering_Name: SUBTRACT; Window_Size_7; Selected_Sample_Number_perClass_15									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	84.71	0.895	0.977	0.879	0.819				
TSVM	92.276	0.924	0.989	0.915	0.903				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	84.636	79.421	79.687	92.113	90.807	86.567	88.504	97.212	92.275
TSVM	86.126	95.758	78.121	96.377	90.062	87.898	93.548	96.64	96.774

Clustering_Name: SUBTRACT; Window_Size_7; Selected_Sample_Number_perClass_30									
	Acc.	Sens.	Spec.	F1score	Kappa				
SVM	90.104	0.912	0.986	0.901	0.879				
TSVM	92.276	0.924	0.989	0.915	0.903				
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
SVM	84.413	90.26	77.72	92.614	92.857	95.648	87.449	96.449	92.105
TSVM	86.126	95.758	78.121	96.377	90.062	87.898	93.548	96.64	96.774

Tablo A.2 Indian Pines veri kümesi için farklı etiketli örnek sayıları ve farklı pencere boyutları için tüm etiketsiz örneklerin SVM ve TSVM ile detaylı sınıflama sonuçları

Clustering_Name: KMEANS; Window_Size_1; Selected_Sample_Number_perClass_1																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	0.049	0.063	0.934	NaN	-0.002											
TSVM	83.023	0.837	0.988	0.816	0.814											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
SVM	2.174	0	0	0	0	0	0	0	0	0	0	0	0	0	0	5.376
TSVM	95.652	79.062	75.663	69.62	80.745	83.151	89.286	95.397	95	79.012	86.354	86.172	94.146	81.818	91.192	72.043
Clustering_Name: KMEANS; Window_Size_1; Selected_Sample_Number_perClass_3																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	75.276	0.77	0.983	0.714	0.732											
TSVM	87.199	0.887	0.991	0.883	0.858											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
SVM	84.783	84.034	66.627	81.013	83.851	57.671	85.714	65.063	90	61.523	86.436	84.823	87.317	55.099	96.114	88.172
TSVM	95.652	80.252	78.916	75.949	92.133	95.342	92.857	94.77	90	80.967	90.672	84.148	96.098	90.435	86.788	92.473
Clustering_Name: KMEANS; Window_Size_1; Selected_Sample_Number_perClass_5																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	79.569	0.77	0.986	0.755	0.777											
TSVM	88.516	0.882	0.992	0.886	0.873											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
SVM	97.826	83.263	81.566	70.886	85.093	70.548	92.857	87.657	95	78.601	87.251	88.533	90.244	52.016	86.528	83.871
TSVM	93.478	86.905	81.446	73.84	92.34	96.438	92.857	95.816	90	81.584	88.88	87.352	95.61	93.518	83.938	95.699
Clustering_Name: KMEANS; Window_Size_1; Selected_Sample_Number_perClass_15																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	82.467	0.794	0.988	0.79	0.808											
TSVM	87.999	0.876	0.991	0.883	0.867											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16

SVM	97.826	80.182	80.843	81.013	90.89	70.411	89.286	93.305	95	86.214	87.006	87.184	93.659	67.036	89.378	86.022
TSVM	97.826	86.905	82.892	73.418	93.996	96.575	92.857	95.397	90	83.539	87.291	85.666	96.098	89.407	86.01	95.699
Clustering_Name: KMEANS; Window_Size_3; Selected_Sample_Number_perClass_1																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	0.01	0.063	0.934	NaN	-0.006											
TSVM	94.478	0.962	0.996	0.951	0.938											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
SVM	2.174	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1.075
TSVM	100	95.588	89.398	79.747	91.718	99.041	100	98.954	95	94.959	94.99	90.556	97.561	96.522	92.487	91.398
Clustering_Name: KMEANS; Window_Size_3; Selected_Sample_Number_perClass_3																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	83.218	0.839	0.989	0.768	0.814											
TSVM	94.897	0.967	0.996	0.955	0.943											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
SVM	93.478	87.465	77.229	74.262	83.644	49.041	100	60.879	95	86.728	95.764	86.003	92.683	77.391	95.596	83.871
TSVM	100	95.938	89.277	79.747	91.925	99.041	100	99.163	95	93.827	96.375	92.58	97.561	96.522	92.746	92.473
Clustering_Name: KMEANS; Window_Size_3; Selected_Sample_Number_perClass_5																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	88.243	0.834	0.992	0.802	0.869											
TSVM	94.634	0.965	0.996	0.954	0.94											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
SVM	97.826	96.709	85.06	89.873	84.058	69.863	100	50.628	100	93.724	92.668	92.243	95.61	88.063	95.855	86.022
TSVM	100	96.709	89.759	81.435	92.133	99.041	100	98.536	95	93.416	94.582	91.568	97.561	97.075	93.523	92.473
Clustering_Name: KMEANS; Window_Size_3; Selected_Sample_Number_perClass_15																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	92.672	0.9	0.995	0.905	0.918											
TSVM	94.399	0.963	0.996	0.949	0.937											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16

SVM	100	95.938	87.831	80.169	91.925	91.233	100	94.77	95	95.576	96.415	85.666	97.561	87.036	94.041	91.398
TSVM	100	96.779	88.554	79.747	91.718	99.041	100	98.745	95	94.136	96.415	81.619	97.561	97.233	92.228	92.473
Clustering_Name: KMEANS; Window_Size_5; Selected_Sample_Number_perClass_1																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	0	0.063	0.935	NaN	-0.008											
TSVM	96.292	0.981	0.997	0.97	0.958											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
SVM	2.174	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
TSVM	100	94.888	92.53	87.764	97.308	98.63	96.429	99.582	100	93.107	99.267	90.388	97.561	98.577	94.301	96.774
Clustering_Name: KMEANS; Window_Size_5; Selected_Sample_Number_perClass_3																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	92.263	0.868	0.995	0.845	0.913											
TSVM	96.292	0.981	0.997	0.97	0.958											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
SVM	97.826	98.109	92.53	70.042	92.961	78.904	96.429	76.569	100	96.605	96.823	88.027	93.659	94.466	84.715	92.473
TSVM	100	94.888	92.53	87.764	97.308	98.63	96.429	99.582	100	93.107	99.267	90.388	97.561	98.577	94.301	96.774
Clustering_Name: KMEANS; Window_Size_5; Selected_Sample_Number_perClass_5																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	92.868	0.932	0.995	0.921	0.92											
TSVM	96.292	0.981	0.997	0.97	0.958											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
SVM	100	98.039	90.482	81.435	90.476	92.877	96.429	91.004	100	94.65	91.772	84.148	96.098	95.81	94.819	90.323
TSVM	100	94.888	92.53	87.764	97.308	98.63	96.429	99.582	100	93.107	99.267	90.388	97.561	98.577	94.301	96.774
Clustering_Name: KMEANS; Window_Size_5; Selected_Sample_Number_perClass_15																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	96.019	0.925	0.997	0.929	0.955											
TSVM	96.292	0.981	0.997	0.97	0.958											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16

SVM	100	94.748	93.012	87.342	97.308	93.562	96.429	99.582	100	95.679	99.022	90.219	95.61	98.577	93.523	93.548
TSVM	100	94.888	92.53	87.764	97.308	98.63	96.429	99.582	100	93.107	99.267	90.388	97.561	98.577	94.301	96.774
Clustering_Name: KMEANS; Window_Size_7; Selected_Sample_Number_perClass_1																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	0	0.063	0.934	NaN	-0.004											
TSVM	96.556	0.98	0.998	0.969	0.961											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
SVM	2.174	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
TSVM	100	98.249	97.711	81.013	96.48	98.219	100	98.536	95	97.222	96.415	92.243	97.561	98.498	89.637	98.925
Clustering_Name: KMEANS; Window_Size_7; Selected_Sample_Number_perClass_3																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	57.489	0.886	0.972	0.725	0.558											
TSVM	96.751	0.966	0.998	0.964	0.963											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
SVM	97.826	32.983	16.506	100	87.164	79.726	100	82.427	90	57.613	49.491	40.304	95.122	78.972	68.135	94.624
TSVM	97.826	98.669	95.783	92.827	96.48	98.63	100	98.536	95	95.988	96.864	91.062	98.049	98.656	90.933	98.925
Clustering_Name: KMEANS; Window_Size_7; Selected_Sample_Number_perClass_5																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	86.204	0.88	0.99	0.868	0.849											
TSVM	96.556	0.98	0.998	0.969	0.961											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
SVM	97.826	79.342	83.373	78.059	96.48	83.014	100	85.356	95	99.794	79.063	80.944	98.049	95.02	95.078	98.925
TSVM	100	98.249	97.711	81.013	96.48	98.219	100	98.536	95	97.222	96.415	92.243	97.561	98.498	89.637	98.925
Clustering_Name: KMEANS; Window_Size_7; Selected_Sample_Number_perClass_15																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	92.829	0.941	0.995	0.929	0.92											
TSVM	96.409	0.965	0.997	0.962	0.959											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16

SVM	97.826	88.095	97.47	97.468	95.652	96.027	100	95.188	95	90.329	95.316	81.45	95.61	94.466	83.42	98.925
TSVM	100	95.658	97.47	90.717	96.48	98.493	100	98.745	95	92.695	98.208	91.4	97.561	98.577	90.674	96.774
Clustering_Name: MEANSHIFT; Window_Size_1; Selected_Sample_Number_perClass_1																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	0.049	0.063	0.934	NaN	-0.003											
TSVM	81.364	0.83	0.987	0.814	0.798											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
SVM	2.174	0	0	0	0	0	0	0	0	0	0	0	0	0	0	5.376
TSVM	95.652	72.199	81.566	77.637	72.464	90.685	89.286	95.188	90	88.272	76.415	83.474	92.683	84.743	90.674	55.914
Clustering_Name: MEANSHIFT; Window_Size_1; Selected_Sample_Number_perClass_3																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	45.907	0.698	0.965	0.495	0.447											
TSVM	84.33	0.806	0.989	0.812	0.829											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
SVM	97.826	39.356	98.313	13.502	88.199	61.096	100	34.31	100	72.119	9.124	60.371	94.146	31.937	58.29	65.591
TSVM	100	75	84.699	66.245	92.547	95.89	92.857	93.515	95	84.774	79.674	84.317	98.049	92.885	75.907	83.871
Clustering_Name: MEANSHIFT; Window_Size_1; Selected_Sample_Number_perClass_5																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	56.103	0.692	0.971	0.598	0.547											
TSVM	85.784	0.796	0.99	0.817	0.843											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
SVM	97.826	54.342	96.867	59.916	83.851	50	100	61.715	90	65.329	23.625	70.152	90.244	50.672	88.342	79.57
TSVM	97.826	79.482	83.855	70.886	92.961	86.849	96.429	93.305	90	76.852	87.495	84.148	98.049	93.043	82.124	91.398
Clustering_Name: MEANSHIFT; Window_Size_1; Selected_Sample_Number_perClass_15																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	79.139	0.765	0.985	0.756	0.774											
TSVM	85.735	0.848	0.99	0.843	0.844											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16

SVM	97.826	59.034	87.47	79.747	90.89	71.781	96.429	90.795	95	81.379	87.251	87.521	93.659	64.585	84.456	83.871
TSVM	97.826	76.331	82.892	64.979	92.547	96.164	92.857	98.326	90	87.037	81.466	86.847	95.122	93.597	82.902	93.548
Clustering_Name: MEANSHIFT; Window_Size_3; Selected_Sample_Number_perClass_1																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	0	0.063	0.935	NaN	-0.01											
TSVM	94.429	0.958	0.996	0.949	0.937											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
SVM	2.174	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
TSVM	100	95.728	89.157	79.325	91.304	98.904	100	98.745	95	95.165	94.908	90.894	97.561	96.522	91.71	92.473
Clustering_Name: MEANSHIFT; Window_Size_3; Selected_Sample_Number_perClass_3																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	58.572	0.736	0.972	0.712	0.567											
TSVM	93.599	0.94	0.996	0.929	0.928											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
SVM	67.391	79.972	45.542	72.996	95.031	69.452	100	29.916	95	99.177	30.143	0	97.561	69.012	65.285	86.022
TSVM	100	96.008	89.157	78.481	94.617	99.041	100	97.49	95	96.502	96.415	67.791	98.049	96.601	88.342	92.473
Clustering_Name: MEANSHIFT; Window_Size_3; Selected_Sample_Number_perClass_5																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	72.758	0.804	0.981	0.703	0.708											
TSVM	93.502	0.94	0.995	0.933	0.927											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
SVM	97.826	86.134	42.53	77.215	95.859	62.877	100	45.816	95	99.074	71.976	53.794	97.073	69.96	63.472	86.022
TSVM	100	96.499	88.434	79.747	95.238	99.041	100	98.954	95	93.416	95.316	70.658	98.537	96.364	92.746	93.548
Clustering_Name: MEANSHIFT; Window_Size_3; Selected_Sample_Number_perClass_15																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	84.916	0.886	0.989	0.862	0.836											
TSVM	94.468	0.965	0.996	0.952	0.938											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16

SVM	100	90.056	79.277	67.089	94.824	98.082	100	88.912	95	91.049	70.061	98.145	97.561	91.067	74.352	88.172
TSVM	100	96.779	88.675	81.435	94.617	99.726	100	99.163	95	94.65	94.99	87.184	97.561	97.312	86.269	92.473
Clustering_Name: MEANSHIFT; Window_Size_5; Selected_Sample_Number_perClass_1																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	0	0.063	0.935	NaN	-0.008											
TSVM	96.292	0.981	0.997	0.97	0.958											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
SVM	2.174	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
TSVM	100	94.888	92.53	87.764	97.308	98.63	96.429	99.582	100	93.107	99.267	90.388	97.561	98.577	94.301	96.774
Clustering_Name: MEANSHIFT; Window_Size_5; Selected_Sample_Number_perClass_3																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	80.183	0.797	0.986	0.734	0.785											
TSVM	96.292	0.981	0.997	0.97	0.958											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
SVM	100	80.742	50.12	85.232	86.335	96.438	96.429	53.975	100	99.177	79.919	85.835	93.659	75.731	81.347	81.72
TSVM	100	94.888	92.53	87.764	97.308	98.63	96.429	99.582	100	93.107	99.267	90.388	97.561	98.577	94.301	96.774
Clustering_Name: MEANSHIFT; Window_Size_5; Selected_Sample_Number_perClass_5																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	70.417	0.834	0.98	0.761	0.688											
TSVM	96.292	0.981	0.997	0.97	0.958											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
SVM	100	71.359	27.349	82.7	98.137	96.301	96.429	85.774	100	99.691	34.216	85.497	92.683	94.15	81.606	89.247
TSVM	100	94.888	92.53	87.764	97.308	98.63	96.429	99.582	100	93.107	99.267	90.388	97.561	98.577	94.301	96.774
Clustering_Name: MEANSHIFT; Window_Size_5; Selected_Sample_Number_perClass_15																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	85.833	0.853	0.99	0.833	0.846											
TSVM	96.292	0.981	0.997	0.97	0.958											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16

SVM	100	95.518	87.47	84.81	94.617	93.562	100	89.958	100	98.868	62.2	89.545	97.561	97.708	76.943	96.774
TSVM	100	94.888	92.53	87.764	97.308	98.63	96.429	99.582	100	93.107	99.267	90.388	97.561	98.577	94.301	96.774
Clustering_Name: MEANSHIFT; Window_Size_7; Selected_Sample_Number_perClass_1																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	0	0.063	0.934	NaN	-0.004											
TSVM	96.556	0.98	0.998	0.969	0.961											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
SVM	2.174	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
TSVM	100	98.249	97.711	81.013	96.48	98.219	100	98.536	95	97.222	96.415	92.243	97.561	98.498	89.637	98.925
Clustering_Name: MEANSHIFT; Window_Size_7; Selected_Sample_Number_perClass_3																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	50.932	0.928	0.968	0.726	0.495											
TSVM	96.595	0.967	0.998	0.967	0.962											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
SVM	95.652	3/24/01	6.988	100	88.199	90.548	100	89.749	90	57.613	14.175	74.03	95.61	92.095	46.114	92.473
TSVM	100	98.319	94.096	96.203	97.308	98.63	100	99.163	95	95.37	95.56	95.784	98.049	98.498	91.192	96.774
Clustering_Name: MEANSHIFT; Window_Size_7; Selected_Sample_Number_perClass_5																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	63.977	0.846	0.976	0.753	0.625											
TSVM	95.004	0.964	0.997	0.95	0.944											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
SVM	97.826	38.165	81.566	99.156	94.203	75.616	100	87.866	90	70.473	31.935	81.788	96.098	87.826	59.845	95.699
TSVM	97.826	95.028	96.988	91.561	96.48	98.493	100	99.163	95	92.181	99.226	65.261	98.049	98.656	90.415	96.774
Clustering_Name: MEANSHIFT; Window_Size_7; Selected_Sample_Number_perClass_15																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	90.243	0.934	0.993	0.916	0.891											
TSVM	96.361	0.973	0.997	0.967	0.959											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16

SVM	97.826	67.437	99.398	89.03	96.273	98.082	100	94.77	95	82.407	97.352	83.474	97.073	98.103	80.311	94.624
TSVM	100	94.748	98.313	91.983	97.308	98.63	100	99.791	95	90.638	98.819	88.364	97.561	98.893	92.228	97.849
Clustering_Name: SUBTRACT; Window_Size_1; Selected_Sample_Number_perClass_1																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	0.088	0.063	0.933	NaN	-0.003											
TSVM	83.657	0.852	0.988	0.832	0.82											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
SVM	2.174	0	0	0	0	0	0	0	0	0	0	0	0	0	0	9.677
TSVM	93.478	74.37	82.53	60.338	61.905	90.822	92.857	96.025	90	82.305	88.554	82.462	89.756	89.407	87.306	65.591
Clustering_Name: SUBTRACT; Window_Size_1; Selected_Sample_Number_perClass_3																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	64.923	0.749	0.976	0.626	0.627											
TSVM	87.16	0.857	0.991	0.864	0.858											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
SVM	97.826	90.966	66.747	32.068	86.957	46.301	92.857	49.372	90	48.045	68.35	68.297	85.854	48.854	64.249	53.763
TSVM	97.826	81.162	79.277	77.215	92.754	95.205	92.857	95.188	90	81.379	90.224	83.811	94.146	90.356	83.161	92.473
Clustering_Name: SUBTRACT; Window_Size_1; Selected_Sample_Number_perClass_5																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	78.193	0.781	0.985	0.726	0.761											
TSVM	87.989	0.865	0.991	0.868	0.867											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
SVM	97.826	87.745	80.602	48.945	84.679	45.068	96.429	82.218	95	66.049	91.283	82.125	84.878	64.822	81.347	81.72
TSVM	97.826	87.325	80.602	73.84	93.582	92.877	92.857	95.397	90	78.909	89.572	84.654	94.146	94.387	80.311	93.548
Clustering_Name: SUBTRACT; Window_Size_1; Selected_Sample_Number_perClass_15																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	81.627	0.806	0.987	0.801	0.799											
TSVM	88.018	0.874	0.991	0.877	0.867											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16

SVM	97.826	79.762	76.988	80.591	87.992	81.233	96.429	93.933	90	68.107	87.739	75.548	93.171	78.024	82.642	84.946
TSVM	97.826	81.022	80.964	68.776	93.789	96.027	92.857	96.234	90	83.333	90.957	86.341	97.073	93.439	79.534	89.247
Clustering_Name: SUBTRACT; Window_Size_3; Selected_Sample_Number_perClass_1																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	0.01	0.063	0.935	NaN	-0.005											
TSVM	93.707	0.958	0.996	0.944	0.929											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
SVM	2.174	0	0	0	0	0	0	0	0	0	0	0	0.488	0	0	0
TSVM	100	93.137	86.867	75.949	90.89	98.904	100	98.745	95	93.107	95.031	93.761	98.049	97.866	84.974	92.473
Clustering_Name: SUBTRACT; Window_Size_3; Selected_Sample_Number_perClass_3																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	74.885	0.836	0.983	0.725	0.73											
TSVM	94.038	0.967	0.996	0.95	0.933											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
SVM	100	97.479	52.651	53.586	91.718	61.233	100	43.933	100	97.428	62.648	86.509	97.561	85.534	43.005	84.946
TSVM	100	96.849	88.916	75.949	91.304	98.767	100	99.372	95	92.901	94.582	89.545	97.561	97.391	86.269	92.473
Clustering_Name: SUBTRACT; Window_Size_3; Selected_Sample_Number_perClass_5																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	89.072	0.864	0.992	0.844	0.878											
TSVM	95.034	0.966	0.996	0.956	0.944											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
SVM	100	92.297	87.711	59.916	81.988	75.616	100	95.188	95	91.667	95.479	85.835	98.049	82.767	96.632	86.022
TSVM	100	96.289	89.398	81.013	91.925	98.219	100	98.745	95	94.239	95.927	94.435	97.561	96.917	93.782	92.473
Clustering_Name: SUBTRACT; Window_Size_3; Selected_Sample_Number_perClass_15																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	92.194	0.886	0.995	0.882	0.913											
TSVM	94.936	0.967	0.996	0.956	0.943											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16

SVM	97.826	96.709	88.313	66.667	84.886	96.986	100	97.49	100	93.519	94.99	91.4	98.049	83.874	95.596	92.473
TSVM	100	96.499	89.398	79.747	91.925	99.041	100	98.954	95	93.621	95.927	92.58	97.561	96.996	93.523	92.473
Clustering_Name: SUBTRACT; Window_Size_5; Selected_Sample_Number_perClass_1																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	0	0.063	0.934	NaN	-0.006											
TSVM	96.292	0.981	0.997	0.97	0.958											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
SVM	2.174	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
TSVM	100	94.888	92.53	87.764	97.308	98.63	96.429	99.582	100	93.107	99.267	90.388	97.561	98.577	94.301	96.774
Clustering_Name: SUBTRACT; Window_Size_5; Selected_Sample_Number_perClass_3																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	79.725	0.88	0.986	0.808	0.78											
TSVM	96.292	0.981	0.997	0.97	0.958											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
SVM	100	46.429	78.434	32.489	81.366	84.658	96.429	79.916	100	99.897	78.452	84.992	97.561	98.103	96.114	87.097
TSVM	100	94.888	92.53	87.764	97.308	98.63	96.429	99.582	100	93.107	99.267	90.388	97.561	98.577	94.301	96.774
Clustering_Name: SUBTRACT; Window_Size_5; Selected_Sample_Number_perClass_5																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	92.136	0.893	0.995	0.873	0.911											
TSVM	96.292	0.981	0.997	0.97	0.958											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
SVM	100	95.308	83.373	80.169	93.789	86.712	92.857	65.9	100	89.198	99.185	88.196	97.561	96.126	98.187	93.548
TSVM	100	94.888	92.53	87.764	97.308	98.63	96.429	99.582	100	93.107	99.267	90.388	97.561	98.577	94.301	96.774
Clustering_Name: SUBTRACT; Window_Size_5; Selected_Sample_Number_perClass_15																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	95.629	0.979	0.997	0.965	0.951											
TSVM	96.292	0.981	0.997	0.97	0.958											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16

SVM	100	97.199	91.928	87.342	96.894	96.438	96.429	93.933	100	95.165	98.33	88.702	98.049	96.601	90.933	96.774
TSVM	100	94.888	92.53	87.764	97.308	98.63	96.429	99.582	100	93.107	99.267	90.388	97.561	98.577	94.301	96.774
Clustering_Name: SUBTRACT; Window_Size_7; Selected_Sample_Number_perClass_1																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	0	0.063	0.934	NaN	-0.007											
TSVM	96.205	0.981	0.997	0.966	0.957											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
SVM	2.174	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
TSVM	100	98.459	96.627	77.215	96.48	98.219	100	98.536	95	94.239	96.701	92.074	97.561	98.498	90.155	98.925
Clustering_Name: SUBTRACT; Window_Size_7; Selected_Sample_Number_perClass_3																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	56.854	0.936	0.971	0.766	0.554											
TSVM	96.751	0.966	0.998	0.964	0.963											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
SVM	93.478	22.899	82.651	98.734	87.992	89.315	100	80.126	90	42.901	35.112	35.919	95.61	82.134	55.699	95.699
TSVM	97.826	98.669	95.783	92.827	96.48	98.63	100	98.536	95	95.988	96.864	91.062	98.049	98.656	90.933	98.925
Clustering_Name: SUBTRACT; Window_Size_7; Selected_Sample_Number_perClass_5																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	82.789	0.929	0.988	0.877	0.813											
TSVM	96.751	0.966	0.998	0.964	0.963											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
SVM	97.826	78.501	75.422	99.156	87.992	96.164	100	92.469	90	89.095	72.953	74.368	96.098	91.937	77.979	90.323
TSVM	97.826	98.669	95.783	92.827	96.48	98.63	100	98.536	95	95.988	96.864	91.062	98.049	98.656	90.933	98.925
Clustering_Name: SUBTRACT; Window_Size_7; Selected_Sample_Number_perClass_15																
	Acc.	Sens.	Spec.	F1score	Kappa											
SVM	92.858	0.95	0.995	0.929	0.92											
TSVM	96.751	0.966	0.998	0.964	0.963											
Acc.	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16

SVM	97.826	92.647	87.229	97.89	92.133	96.575	100	94.77	95	93.313	95.316	78.246	97.561	95.731	85.233	98.925
TSVM	97.826	98.669	95.783	92.827	96.48	98.63	100	98.536	95	95.988	96.864	91.062	98.049	98.656	90.933	98.925

Tablo A.3 Pavia Üniversite veri kümesi için farklı etiketli örnek sayıları ve farklı pencere boyutları için tüm etiketsiz örneklerin S^3RC ile detaylı sınıflama sonuçları (%)

Clustering_Name: KMEANS; Window_Size_1; Selected_Sample_Number_perClass_1									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC_{train}	94,31	0,94	0,993	0,941	0,936				
S^3RC_{test}	83,12	0,814	0,975	0,835	0,802				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC_{train}	91,606	99,259	93,622	98,664	100	99,812	100	72,763	100
S^3RC_{test}	80,011	79,077	83,26	85,981	99,752	93,724	97,067	73,594	100
Clustering_Name: KMEANS; Window_Size_1; Selected_Sample_Number_perClass_3									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC_{train}	96,66	0,962	0,996	0,965	0,962				
S^3RC_{test}	82,26	0,848	0,974	0,854	0,795				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC_{train}	95,62	97,963	89,286	97,137	100	99,812	100	92,607	100
S^3RC_{test}	85,304	72,635	70,775	83,891	99,752	95,81	95,894	91,325	99,915
Clustering_Name: KMEANS; Window_Size_1; Selected_Sample_Number_perClass_5									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC_{train}	96,97	0,965	0,996	0,968	0,966				
S^3RC_{test}	84,5	0,841	0,977	0,857	0,817				

	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S ³ RCtrain	95,803	99,259	92,092	98,664	100	99,812	100	89,689	100
S ³ RCtest	83,257	79,066	72,943	85,981	99,752	93,706	96,364	89,871	99,83
Clustering_Name: KMEANS; Window_Size_1; Selected_Sample_Number_perClass_15									
	Acc.	Sens.	Spec.	F1score	Kappa				
S ³ RCtrain	96,66	0,968	0,996	0,959	0,962				
S ³ RCtest	84,86	0,842	0,978	0,834	0,82				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S ³ RCtrain	98,54	99,815	94,388	98,664	100	99,812	100	93,58	74,459
S ³ RCtest	85,583	81,807	71,216	85,424	99,752	92,519	95,894	91,897	59,932
Clustering_Name: KMEANS; Window_Size_1; Selected_Sample_Number_perClass_30									
	Acc.	Sens.	Spec.	F1score	Kappa				
S ³ RCtrain	97,86	0,978	0,997	0,975	0,976				
S ³ RCtest	85,03	0,845	0,978	0,836	0,822				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S ³ RCtrain	98,175	99,815	94,133	98,855	100	99,624	100	96,887	88,745
S ³ RCtest	84,928	82,662	67,925	85,758	99,752	91,728	94,135	93,565	62,733
Clustering_Name: KMEANS; Window_Size_3; Selected_Sample_Number_perClass_1									

	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC_{train}	99,52	0,992	0,999	0,993	0,995				
S^3RC_{test}	90,12	0,897	0,985	0,911	0,881				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC_{train}	98,723	100	96,939	100	100	100	100	100	100
S^3RC_{test}	87,394	85,502	80,45	96,6	100	98,238	97,713	95,782	99,745
Clustering_Name: KMEANS; Window_Size_3; Selected_Sample_Number_perClass_3									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC_{train}	99,59	0,993	0,999	0,994	0,995				
S^3RC_{test}	90,16	0,899	0,985	0,912	0,881				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC_{train}	99,27	100	96,939	100	100	100	100	100	100
S^3RC_{test}	87,672	85,502	80,45	96,6	100	98,238	97,713	95,782	99,745
Clustering_Name: KMEANS; Window_Size_3; Selected_Sample_Number_perClass_5									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC_{train}	99,72	0,995	1	0,996	0,997				
S^3RC_{test}	90,11	0,9	0,985	0,911	0,88				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9

S^3RC_{train}	99,453	100	97,959	100	100	100	100	100	100
S^3RC_{test}	87,728	85,502	78,764	96,6	100	98,238	97,713	96,235	99,406
Clustering_Name: KMEANS; Window_Size_3; Selected_Sample_Number_perClass_15									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC_{train}	99,92	0,999	1	0,999	0,999				
S^3RC_{test}	90,16	0,9	0,985	0,912	0,881				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC_{train}	99,453	100	100	100	100	100	100	100	100
S^3RC_{test}	87,714	85,502	80,931	96,6	100	98,238	97,713	95,782	98,387
Clustering_Name: KMEANS; Window_Size_3; Selected_Sample_Number_perClass_30									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC_{train}	99,92	0,999	1	0,999	0,999				
S^3RC_{test}	90,16	0,9	0,985	0,912	0,881				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC_{train}	99,453	100	100	100	100	100	100	100	100
S^3RC_{test}	87,714	85,502	80,931	96,6	100	98,238	97,713	95,782	98,387
Clustering_Name: KMEANS; Window_Size_5; Selected_Sample_Number_perClass_1									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC_{train}	100	1	1	1	1				

S^3RC test	91,71	0,909	0,988	0,918	0,898				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC train	100	100	100	100	100	100	100	100	100
S^3RC test	86,14	90,281	80,731	98,523	100	96,08	96,188	96,187	97,029
Clustering_Name: KMEANS; Window_Size_5; Selected_Sample_Number_perClass_3									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC train	100	1	1	1	1				
S^3RC test	91,71	0,909	0,988	0,918	0,898				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC train	100	100	100	100	100	100	100	100	100
S^3RC test	86,14	90,281	80,731	98,523	100	96,08	96,188	96,187	97,029
Clustering_Name: KMEANS; Window_Size_5; Selected_Sample_Number_perClass_5									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC train	100	1	1	1	1				
S^3RC test	91,71	0,909	0,988	0,918	0,898				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC train	100	100	100	100	100	100	100	100	100
S^3RC test	86,14	90,281	80,731	98,523	100	96,08	96,188	96,187	97,029

[illegible]

	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC_{train}	100	100	100	100	100	100	100	100	100
S^3RC_{test}	83,02	92,621	78,402	98,3	100	92,609	95,073	95,782	97,284
Clustering_Name: KMEANS; Window_Size_7; Selected_Sample_Number_perClass_3									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC_{train}	100	1	1	1	1				
S^3RC_{test}	91,57	0,9	0,988	0,91	0,896				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC_{train}	100	100	100	100	100	100	100	100	100
S^3RC_{test}	83,02	92,621	78,402	98,3	100	92,609	95,073	95,782	97,284
Clustering_Name: KMEANS; Window_Size_7; Selected_Sample_Number_perClass_5									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC_{train}	100	1	1	1	1				
S^3RC_{test}	91,57	0,9	0,988	0,91	0,896				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC_{train}	100	100	100	100	100	100	100	100	100
S^3RC_{test}	83,02	92,621	78,402	98,3	100	92,609	95,073	95,782	97,284
Clustering_Name: KMEANS; Window_Size_7; Selected_Sample_Number_perClass_15									
	Acc.	Sens.	Spec.	F1score	Kappa				

S^3RC train	100	1	1	1	1				
S^3RC test	91,57	0,9	0,988	0,91	0,896				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC train	100	100	100	100	100	100	100	100	100
S^3RC test	83,02	92,621	78,402	98,3	100	92,609	95,073	95,782	97,284
Clustering_Name: KMEANS; Window_Size_7; Selected_Sample_Number_perClass_30									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC train	100	1	1	1	1				
S^3RC test	91,57	0,9	0,988	0,91	0,896				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC train	100	100	100	100	100	100	100	100	100
S^3RC test	83,02	92,621	78,402	98,3	100	92,609	95,073	95,782	97,284
Clustering_Name: MEANSHIFT; Window_Size_1; Selected_Sample_Number_perClass_1									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC train	92,43	0,927	0,991	0,923	0,916				
S^3RC test	81,52	0,809	0,973	0,823	0,785				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC train	89,416	98,704	92,092	98,664	100	99,812	100	62,451	100

S^3RC test	79,189	76,57	89,482	85,981	99,752	94,443	97,537	63,775	100
Clustering_Name: MEANSHIFT; Window_Size_1; Selected_Sample_Number_perClass_3									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC train	90,95	0,927	0,989	0,861	0,899				
S^3RC test	82,72	0,813	0,975	0,772	0,796				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC train	94,526	90,556	91,582	99,237	100	99,436	100	92,607	15,152
S^3RC test	83,368	80,03	70,895	86,093	99,689	91,926	96,774	90,801	21,647
Clustering_Name: MEANSHIFT; Window_Size_1; Selected_Sample_Number_perClass_5									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC train	92,07	0,937	0,991	0,879	0,911				
S^3RC test	81,02	0,808	0,973	0,749	0,779				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC train	96,898	95	91,071	99,237	100	99,248	100	91,44	22,078
S^3RC test	83,605	76,028	69,57	86,037	99,689	93,418	96,598	91,516	11,63
Clustering_Name: MEANSHIFT; Window_Size_1; Selected_Sample_Number_perClass_15									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC train	93,11	0,944	0,992	0,895	0,923				
S^3RC test	80,92	0,811	0,973	0,749	0,777				

	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S ³ RCtrain	97,628	95,556	91,582	98,282	100	99,812	100	95,331	28,139
S ³ RCtest	81,906	76,288	68,647	84,838	99,689	93,994	96,364	92,874	12,139
Clustering_Name: MEANSHIFT; Window_Size_1; Selected_Sample_Number_perClass_30									
	Acc.	Sens.	Spec.	F1score	Kappa				
S ³ RCtrain	94,52	0,951	0,993	0,928	0,938				
S ³ RCtest	82,4	0,815	0,975	0,789	0,793				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S ³ RCtrain	96,721	95	90,051	99,046	100	99,436	100	97,471	52,381
S ³ RCtest	79,833	80,035	57,246	85,73	99,689	92,897	96,485	94,805	41,851
Clustering_Name: MEANSHIFT; Window_Size_3; Selected_Sample_Number_perClass_1									
	Acc.	Sens.	Spec.	F1score	Kappa				
S ³ RCtrain	99,49	0,991	0,999	0,993	0,994				
S ³ RCtest	90,12	0,897	0,985	0,911	0,88				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S ³ RCtrain	98,723	100	96,684	100	100	100	100	100	100
S ³ RCtest	87,394	85,502	80,409	96,6	100	98,238	97,713	95,782	99,745
Clustering_Name: MEANSHIFT; Window_Size_3; Selected_Sample_Number_perClass_3									

	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC_{train}	99,72	0,997	1	0,997	0,997				
S^3RC_{test}	89,49	0,888	0,984	0,901	0,873				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC_{train}	99,453	100	97,959	100	100	100	100	100	100
S^3RC_{test}	83,647	85,502	78,764	96,6	100	98,238	98,416	96,235	98,302
Clustering_Name: MEANSHIFT; Window_Size_3; Selected_Sample_Number_perClass_5									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC_{train}	99,8	0,997	1	0,997	0,998				
S^3RC_{test}	90,14	0,901	0,985	0,912	0,881				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC_{train}	100	100	97,959	100	100	100	100	100	100
S^3RC_{test}	87,951	85,502	78,764	96,6	100	98,238	97,713	96,235	98,981
Clustering_Name: MEANSHIFT; Window_Size_3; Selected_Sample_Number_perClass_15									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC_{train}	99,97	1	1	1	1				
S^3RC_{test}	91,62	0,909	0,987	0,919	0,897				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9

S^3RC_{train}	100	100	100	100	100	99,812	100	100	100
S^3RC_{test}	87,909	89,301	80,931	96,6	100	97,195	97,713	95,782	97,963
Clustering_Name: MEANSHIFT; Window_Size_3; Selected_Sample_Number_perClass_30									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC_{train}	100	1	1	1	1				
S^3RC_{test}	90,18	0,901	0,985	0,912	0,881				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC_{train}	100	100	100	100	100	100	100	100	100
S^3RC_{test}	87,909	85,502	80,931	96,6	100	98,238	97,713	95,782	97,963
Clustering_Name: MEANSHIFT; Window_Size_5; Selected_Sample_Number_perClass_1									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC_{train}	100	1	1	1	1				
S^3RC_{test}	91,71	0,909	0,988	0,918	0,898				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC_{train}	100	100	100	100	100	100	100	100	100
S^3RC_{test}	86,14	90,281	80,731	98,523	100	96,08	96,188	96,187	97,029
Clustering_Name: MEANSHIFT; Window_Size_5; Selected_Sample_Number_perClass_3									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC_{train}	100	1	1	1	1				

S^3RC test	91,71	0,909	0,988	0,918	0,898				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC train	100	100	100	100	100	100	100	100	100
S^3RC test	86,14	90,281	80,731	98,523	100	96,08	96,188	96,187	97,029
Clustering_Name: MEANSHIFT; Window_Size_5; Selected_Sample_Number_perClass_5									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC train	100	1	1	1	1				
S^3RC test	91,71	0,909	0,988	0,918	0,898				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC train	100	100	100	100	100	100	100	100	100
S^3RC test	86,14	90,281	80,731	98,523	100	96,08	96,188	96,187	97,029
Clustering_Name: MEANSHIFT; Window_Size_5; Selected_Sample_Number_perClass_15									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC train	100	1	1	1	1				
S^3RC test	91,71	0,909	0,988	0,918	0,898				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC train	100	100	100	100	100	100	100	100	100
S^3RC test	86,14	90,281	80,731	98,523	100	96,08	96,188	96,187	97,029

[illegible]

	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC_{train}	100	100	100	100	100	100	100	100	100
S^3RC_{test}	83,02	92,621	78,402	98,3	100	92,609	95,073	95,782	97,284
Clustering_Name: MEANSHIFT; Window_Size_7; Selected_Sample_Number_perClass_5									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC_{train}	100	1	1	1	1				
S^3RC_{test}	91,57	0,9	0,988	0,91	0,896				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC_{train}	100	100	100	100	100	100	100	100	100
S^3RC_{test}	83,02	92,621	78,402	98,3	100	92,609	95,073	95,782	97,284
Clustering_Name: MEANSHIFT; Window_Size_7; Selected_Sample_Number_perClass_15									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC_{train}	100	1	1	1	1				
S^3RC_{test}	91,57	0,9	0,988	0,91	0,896				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC_{train}	100	100	100	100	100	100	100	100	100
S^3RC_{test}	83,02	92,621	78,402	98,3	100	92,609	95,073	95,782	97,284
Clustering_Name: MEANSHIFT; Window_Size_7; Selected_Sample_Number_perClass_30									
	Acc.	Sens.	Spec.	F1score	Kappa				

S^3RC train	100	1	1	1	1				
S^3RC test	91,57	0,9	0,988	0,91	0,896				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC train	100	100	100	100	100	100	100	100	100
S^3RC test	83,02	92,621	78,402	98,3	100	92,609	95,073	95,783	97,284
Clustering_Name: SUBTRACTIVE; Window_Size_1; Selected_Sample_Number_perClass_1									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC train	92,53	0,924	0,991	0,924	0,917				
S^3RC test	80,42	0,796	0,972	0,819	0,775				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC train	91,606	95,556	86,99	98,664	100	99,812	100	68,093	100
S^3RC test	82,323	72,031	75,913	87,848	99,752	94,372	96,891	73,737	100
Clustering_Name: SUBTRACTIVE; Window_Size_1; Selected_Sample_Number_perClass_3									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC train	94,62	0,944	0,993	0,946	0,94				
S^3RC test	84,73	0,842	0,977	0,857	0,819				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC train	94,891	99,63	90,306	96,183	100	99,812	100	76,265	100

S^3RC test	85,277	81,208	81,132	83,445	99,752	93,724	96,481	76,43	100
Clustering_Name: SUBTRACTIVE; Window_Size_1; Selected_Sample_Number_perClass_5									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC train	96,66	0,963	0,996	0,965	0,962				
S^3RC test	86,06	0,856	0,979	0,872	0,834				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC train	96,35	99,815	92,092	98,664	100	99,624	100	86,381	100
S^3RC test	87,324	81,776	78,483	85,73	99,752	92,627	95,836	86,487	99,83
Clustering_Name: SUBTRACTIVE; Window_Size_1; Selected_Sample_Number_perClass_15									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC train	97,19	0,968	0,996	0,971	0,968				
S^3RC test	86,1	0,859	0,979	0,871	0,834				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC train	96,715	99,815	91,327	98,473	100	99,812	100	90,661	100
S^3RC test	87,059	81,964	74,267	85,284	99,752	92,645	95,836	89,299	99,915
Clustering_Name: SUBTRACTIVE; Window_Size_1; Selected_Sample_Number_perClass_30									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC train	97,25	0,969	0,997	0,971	0,969				
S^3RC test	86,45	0,865	0,98	0,875	0,838				

	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S ³ RCtrain	97,08	99,63	91,582	97,901	100	99,624	100	91,44	100
S ³ RCtest	87,547	82,74	74,589	84,755	99,752	92,897	94,135	89,538	99,83
Clustering_Name: SUBTRACTIVE; Window_Size_3; Selected_Sample_Number_perClass_1									
	Acc.	Sens.	Spec.	F1score	Kappa				
S ³ RCtrain	99,67	0,994	1	0,995	0,996				
S ³ RCtest	89,35	0,89	0,984	0,906	0,872				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S ³ RCtrain	99,088	99,815	98,214	100	100	100	100	100	100
S ³ RCtest	87,631	83,511	80,65	96,683	100	98,238	97,713	95,782	99,406
Clustering_Name: SUBTRACTIVE; Window_Size_3; Selected_Sample_Number_perClass_3									
	Acc.	Sens.	Spec.	F1score	Kappa				
S ³ RCtrain	99,57	0,992	0,999	0,994	0,995				
S ³ RCtest	90,16	0,899	0,985	0,912	0,881				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S ³ RCtrain	99,088	100	96,939	100	100	100	100	100	100
S ³ RCtest	87,617	85,502	80,45	96,6	100	98,238	97,713	95,782	99,745
Clustering_Name: SUBTRACTIVE; Window_Size_3; Selected_Sample_Number_perClass_5									

	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC_{train}	99,62	0,993	1	0,994	0,996				
S^3RC_{test}	90,17	0,899	0,985	0,912	0,881				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC_{train}	99,453	100	96,939	100	100	100	100	100	100
S^3RC_{test}	87,728	85,502	80,45	96,6	100	98,238	97,713	95,782	99,745
Clustering_Name: SUBTRACTIVE; Window_Size_3; Selected_Sample_Number_perClass_15									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC_{train}	99,72	0,995	1	0,996	0,997				
S^3RC_{test}	90,18	0,9	0,985	0,912	0,881				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC_{train}	99,453	100	97,959	100	100	100	100	100	100
S^3RC_{test}	87,728	85,502	80,61	96,6	100	98,238	97,713	95,782	99,66
Clustering_Name: SUBTRACTIVE; Window_Size_3; Selected_Sample_Number_perClass_30									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC_{train}	99,69	0,995	1	0,996	0,997				
S^3RC_{test}	90,18	0,9	0,985	0,912	0,881				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9

S^3RC_{train}	99,453	100	97,704	100	100	100	100	100	100
S^3RC_{test}	87,728	85,502	80,57	96,6	100	98,238	97,713	95,782	99,66
Clustering_Name: SUBTRACTIVE; Window_Size_5; Selected_Sample_Number_perClass_1									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC_{train}	100	1	1	1	1				
S^3RC_{test}	91,71	0,909	0,988	0,918	0,898				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC_{train}	100	100	100	100	100	100	100	100	100
S^3RC_{test}	86,14	90,281	80,731	98,523	100	96,08	96,188	96,187	97,029
Clustering_Name: SUBTRACTIVE; Window_Size_5; Selected_Sample_Number_perClass_3									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC_{train}	100	1	1	1	1				
S^3RC_{test}	91,71	0,909	0,988	0,918	0,898				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC_{train}	100	100	100	100	100	100	100	100	100
S^3RC_{test}	86,14	90,281	80,731	98,523	100	96,08	96,188	96,187	97,029
Clustering_Name: SUBTRACTIVE; Window_Size_5; Selected_Sample_Number_perClass_5									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC_{train}	100	1	1	1	1				

S^3RC test	91,71	0,909	0,988	0,918	0,898				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC train	100	100	100	100	100	100	100	100	100
S^3RC test	86,14	90,281	80,731	98,523	100	96,08	96,188	96,187	97,029
Clustering_Name: SUBTRACTIVE; Window_Size_5; Selected_Sample_Number_perClass_15									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC train	100	1	1	1	1				
S^3RC test	91,71	0,909	0,988	0,918	0,898				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC train	100	100	100	100	100	100	100	100	100
S^3RC test	86,14	90,281	80,731	98,523	100	96,08	96,188	96,187	97,029
Clustering_Name: SUBTRACTIVE; Window_Size_5; Selected_Sample_Number_perClass_30									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC train	100	1	1	1	1				
S^3RC test	91,71	0,909	0,988	0,918	0,898				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC train	100	100	100	100	100	100	100	100	100
S^3RC test	86,14	90,281	80,731	98,523	100	96,08	96,188	96,187	97,029

[illegible]

	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC_{train}	100	100	100	100	100	100	100	100	100
S^3RC_{test}	83,02	92,621	78,402	98,3	100	92,609	95,073	95,782	97,284
Clustering_Name: SUBTRACTIVE; Window_Size_7; Selected_Sample_Number_perClass_15									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC_{train}	100	1	1	1	1				
S^3RC_{test}	91,57	0,9	0,988	0,91	0,896				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC_{train}	100	100	100	100	100	100	100	100	100
S^3RC_{test}	83,02	92,621	78,402	98,3	100	92,609	95,073	95,782	97,284
Clustering_Name: SUBTRACTIVE; Window_Size_7; Selected_Sample_Number_perClass_30									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC_{train}	100	1	1	1	1				
S^3RC_{test}	91,57	0,9	0,988	0,91	0,896				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC_{train}	100	100	100	100	100	100	100	100	100
S^3RC_{test}	83,02	92,621	78,402	98,3	100	92,609	95,073	95,782	97,284
Clustering_Name: KMEDOID; Window_Size_1; Selected_Sample_Number_perClass_1									
	Acc.	Sens.	Spec.	F1score	Kappa				

S^3RC train	94,31	0,94	0,993	0,941	0,936				
S^3RC test	83,12	0,814	0,975	0,835	0,802				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC train	91,606	99,259	93,622	98,664	100	99,812	100	72,763	100
S^3RC test	80,011	79,077	83,26	85,981	99,752	93,724	97,067	73,594	100
Clustering_Name: KMEDOID; Window_Size_1; Selected_Sample_Number_perClass_3									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC train	96,71	0,963	0,996	0,966	0,963				
S^3RC test	83,28	0,847	0,975	0,857	0,805				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC train	95,073	98,704	91,837	98,473	100	99,812	100	89,494	100
S^3RC test	86,697	74,793	71,778	85,284	99,752	94,983	96,422	89,466	99,915
Clustering_Name: KMEDOID; Window_Size_1; Selected_Sample_Number_perClass_5									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC train	96,35	0,961	0,995	0,961	0,959				
S^3RC test	83,77	0,829	0,976	0,831	0,809				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC train	94,526	99,444	95,663	98,473	100	99,812	100	88,132	90,043

S^3RC test	82,156	79,691	76,556	85,396	99,752	93,706	96,716	87,726	68,761
Clustering_Name: KMEDOID; Window_Size_1; Selected_Sample_Number_perClass_15									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC train	93,75	0,951	0,993	0,9	0,93				
S^3RC test	83,52	0,824	0,976	0,768	0,804				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC train	98,175	99,815	97,704	98,664	100	99,624	100	90,661	27,273
S^3RC test	84,705	82,089	77,961	85,424	99,752	92,429	96,305	86,201	13,158
Clustering_Name: KMEDOID; Window_Size_1; Selected_Sample_Number_perClass_30									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC train	98,04	0,98	0,998	0,978	0,978				
S^3RC test	84,86	0,845	0,978	0,85	0,821				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC train	98,723	99,444	98,214	99,046	100	99,812	100	94,358	89,177
S^3RC test	84,678	80,775	73,946	85,814	99,689	92,411	95,836	90,92	79,457
Clustering_Name: KMEDOID; Window_Size_3; Selected_Sample_Number_perClass_1									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC train	99,52	0,992	0,999	0,993	0,995				
S^3RC test	90,12	0,897	0,985	0,911	0,881				

	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S ³ RCtrain	98,723	100	96,939	100	100	100	100	100	100
S ³ RCtest	87,394	85,502	80,45	96,6	100	98,238	97,713	95,782	99,745
Clustering_Name: KMEDOID; Window_Size_3; Selected_Sample_Number_perClass_3									
	Acc.	Sens.	Spec.	F1score	Kappa				
S ³ RCtrain	99,62	0,993	1	0,995	0,996				
S ³ RCtest	90,16	0,899	0,985	0,912	0,881				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S ³ RCtrain	99,088	100	97,449	100	100	100	100	100	100
S ³ RCtest	87,617	85,502	80,53	96,6	100	98,238	97,713	95,782	99,66
Clustering_Name: KMEDOID; Window_Size_3; Selected_Sample_Number_perClass_5									
	Acc.	Sens.	Spec.	F1score	Kappa				
S ³ RCtrain	99,74	0,995	1	0,996	0,997				
S ³ RCtest	90,17	0,9	0,985	0,912	0,881				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S ³ RCtrain	99,453	100	98,214	100	100	100	100	100	100
S ³ RCtest	87,728	85,502	80,65	96,6	100	98,238	97,713	95,782	99,406
Clustering_Name: KMEDOID; Window_Size_3; Selected_Sample_Number_perClass_15									

	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC_{train}	99,92	0,999	1	0,999	0,999				
S^3RC_{test}	90,16	0,9	0,985	0,912	0,881				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC_{train}	99,453	100	100	100	100	100	100	100	100
S^3RC_{test}	87,714	85,502	80,931	96,6	100	98,238	97,713	95,782	98,387
Clustering_Name: KMEDOID; Window_Size_3; Selected_Sample_Number_perClass_30									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC_{train}	100	1	1	1	1				
S^3RC_{test}	90,18	0,901	0,985	0,912	0,881				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC_{train}	100	100	100	100	100	100	100	100	100
S^3RC_{test}	87,909	85,502	80,931	96,6	100	98,238	97,713	95,782	97,963
Clustering_Name: KMEDOID; Window_Size_5; Selected_Sample_Number_perClass_1									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC_{train}	100	1	1	1	1				
S^3RC_{test}	91,71	0,909	0,988	0,918	0,898				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9

S^3RC_{train}	100	100	100	100	100	100	100	100	100
S^3RC_{test}	86,14	90,281	80,731	98,523	100	96,08	96,188	96,187	97,029
Clustering_Name: KMEDOID; Window_Size_5; Selected_Sample_Number_perClass_3									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC_{train}	100	1	1	1	1				
S^3RC_{test}	91,71	0,909	0,988	0,918	0,898				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC_{train}	100	100	100	100	100	100	100	100	100
S^3RC_{test}	86,14	90,281	80,731	98,523	100	96,08	96,188	96,187	97,029
Clustering_Name: KMEDOID; Window_Size_5; Selected_Sample_Number_perClass_5									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC_{train}	100	1	1	1	1				
S^3RC_{test}	91,71	0,909	0,988	0,918	0,898				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC_{train}	100	100	100	100	100	100	100	100	100
S^3RC_{test}	86,14	90,281	80,731	98,523	100	96,08	96,188	96,187	97,029
Clustering_Name: KMEDOID; Window_Size_5; Selected_Sample_Number_perClass_15									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC_{train}	100	1	1	1	1				

S^3RC test	91,71	0,909	0,988	0,918	0,898				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC train	100	100	100	100	100	100	100	100	100
S^3RC test	86,14	90,281	80,731	98,523	100	96,08	96,188	96,187	97,029
Clustering_Name: KMEDOID; Window_Size_5; Selected_Sample_Number_perClass_30									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC train	100	1	1	1	1				
S^3RC test	91,71	0,909	0,988	0,918	0,898				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC train	100	100	100	100	100	100	100	100	100
S^3RC test	86,14	90,281	80,731	98,523	100	96,08	96,188	96,187	97,029
Clustering_Name: KMEDOID; Window_Size_7; Selected_Sample_Number_perClass_1									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC train	100	1	1	1	1				
S^3RC test	91,57	0,9	0,988	0,91	0,896				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC train	100	100	100	100	100	100	100	100	100
S^3RC test	83,02	92,621	78,402	98,3	100	92,609	95,073	95,782	97,284

[illegible]

	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC_{train}	100	100	100	100	100	100	100	100	100
S^3RC_{test}	83,02	92,621	78,402	98,3	100	92,609	95,073	95,782	97,284
Clustering_Name: KMEDOID; Window_Size_7; Selected_Sample_Number_perClass_30									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC_{train}	100	1	1	1	1				
S^3RC_{test}	91,57	0,9	0,988	0,91	0,896				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC_{train}	100	100	100	100	100	100	100	100	100
S^3RC_{test}	83,02	92,621	78,402	98,3	100	92,609	95,073	95,782	97,284
Clustering_Name: DBSCAN; Window_Size_1; Selected_Sample_Number_perClass_1									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC_{train}	94,31	0,94	0,993	0,941	0,936				
S^3RC_{test}	83,12	0,814	0,975	0,835	0,802				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC_{train}	91,606	99,259	93,622	98,664	100	99,812	100	72,763	100
S^3RC_{test}	80,011	79,077	83,26	85,981	99,752	93,724	97,067	73,594	100
Clustering_Name: DBSCAN; Window_Size_1; Selected_Sample_Number_perClass_3									
	Acc.	Sens.	Spec.	F1score	Kappa				

S^3RC train	95,43	0,95	0,994	0,954	0,949				
S^3RC test	81,29	0,812	0,973	0,834	0,785				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC train	92,153	91,852	93,112	99,237	100	99,624	100	88,521	100
S^3RC test	81,195	71,692	75,391	87,821	99,627	94,12	97,126	87,56	99,83
Clustering_Name: DBSCAN; Window_Size_1; Selected_Sample_Number_perClass_5									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC train	93,19	0,934	0,991	0,935	0,924				
S^3RC test	80,16	0,792	0,971	0,816	0,771				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC train	93,978	87,407	95,408	99,046	100	97,744	100	75,292	98,268
S^3RC test	79,44	73,756	85,628	87,876	99,627	89,912	97,185	68,303	98,812
Clustering_Name: DBSCAN; Window_Size_1; Selected_Sample_Number_perClass_15									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC train	92,25	0,937	0,99	0,911	0,913				
S^3RC test	82,44	0,818	0,975	0,797	0,793				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC train	84,672	95,185	95,918	99,237	100	98,684	100	88,132	54,113

S^3RC test	74,3	81,667	83,621	86,009	99,689	92,052	96,305	82,221	42,954
Clustering_Name: DBSCAN; Window_Size_1; Selected_Sample_Number_perClass_30									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC train	95,43	0,959	0,994	0,953	0,949				
S^3RC test	83,1	0,822	0,976	0,816	0,8				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC train	89,599	96,111	94,388	99,237	100	97,744	100	95,72	82,251
S^3RC test	78,34	81,755	69,691	86,901	99,627	90,577	95,367	86,94	61,545
Clustering_Name: DBSCAN; Window_Size_3; Selected_Sample_Number_perClass_1									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC train	99,52	0,992	0,999	0,993	0,995				
S^3RC test	90,12	0,897	0,985	0,911	0,881				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC train	98,723	100	96,939	100	100	100	100	100	100
S^3RC test	87,394	85,502	80,45	96,6	100	98,238	97,713	95,782	99,745
Clustering_Name: DBSCAN; Window_Size_3; Selected_Sample_Number_perClass_3									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC train	99,67	0,994	1	0,995	0,996				
S^3RC test	90,1	0,899	0,985	0,911	0,88				

	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S ³ RCtrain	99,088	100	97,959	100	100	100	100	100	100
S ³ RCtest	87,631	85,502	78,764	96,6	100	98,238	97,713	96,235	99,406
Clustering_Name: DBSCAN; Window_Size_3; Selected_Sample_Number_perClass_5									
	Acc.	Sens.	Spec.	F1score	Kappa				
S ³ RCtrain	99,74	0,996	1	0,997	0,997				
S ³ RCtest	90,54	0,905	0,986	0,915	0,885				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S ³ RCtrain	99,453	100	98,469	99,809	100	100	100	100	100
S ³ RCtest	87,728	86,576	80,69	95,624	100	98,238	97,713	95,782	99,321
Clustering_Name: DBSCAN; Window_Size_3; Selected_Sample_Number_perClass_15									
	Acc.	Sens.	Spec.	F1score	Kappa				
S ³ RCtrain	99,69	0,997	1	0,997	0,997				
S ³ RCtest	92,27	0,906	0,989	0,917	0,904				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S ³ RCtrain	99,818	100	100	100	100	97,932	100	100	100
S ³ RCtest	84,705	92,98	80,931	96,6	100	93,886	98,358	95,782	97,963
Clustering_Name: DBSCAN; Window_Size_3; Selected_Sample_Number_perClass_30									

	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC_{train}	99,8	0,998	1	0,998	0,998				
S^3RC_{test}	91,32	0,897	0,987	0,91	0,893				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC_{train}	99,635	100	100	100	100	98,872	100	100	100
S^3RC_{test}	83,41	90,432	80,931	96,6	100	96,26	98,768	95,782	97,963
Clustering_Name: DBSCAN; Window_Size_5; Selected_Sample_Number_perClass_1									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC_{train}	100	1	1	1	1				
S^3RC_{test}	91,71	0,909	0,988	0,918	0,898				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC_{train}	100	100	100	100	100	100	100	100	100
S^3RC_{test}	86,14	90,281	80,731	98,523	100	96,08	96,188	96,187	97,029
Clustering_Name: DBSCAN; Window_Size_5; Selected_Sample_Number_perClass_3									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC_{train}	100	1	1	1	1				
S^3RC_{test}	91,71	0,909	0,988	0,918	0,898				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9

S^3RC_{train}	100	100	100	100	100	100	100	100	100
S^3RC_{test}	86,14	90,281	80,731	98,523	100	96,08	96,188	96,187	97,029
Clustering_Name: DBSCAN; Window_Size_5; Selected_Sample_Number_perClass_5									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC_{train}	100	1	1	1	1				
S^3RC_{test}	91,71	0,909	0,988	0,918	0,898				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC_{train}	100	100	100	100	100	100	100	100	100
S^3RC_{test}	86,14	90,281	80,731	98,523	100	96,08	96,188	96,187	97,029
Clustering_Name: DBSCAN; Window_Size_5; Selected_Sample_Number_perClass_15									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC_{train}	100	1	1	1	1				
S^3RC_{test}	91,71	0,909	0,988	0,918	0,898				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC_{train}	100	100	100	100	100	100	100	100	100
S^3RC_{test}	86,14	90,281	80,731	98,523	100	96,08	96,188	96,187	97,029
Clustering_Name: DBSCAN; Window_Size_5; Selected_Sample_Number_perClass_30									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC_{train}	100	1	1	1	1				

S^3RC test	91,71	0,909	0,988	0,918	0,898				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC train	100	100	100	100	100	100	100	100	100
S^3RC test	86,14	90,281	80,731	98,523	100	96,08	96,188	96,187	97,029
Clustering_Name: DBSCAN; Window_Size_7; Selected_Sample_Number_perClass_1									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC train	100	1	1	1	1				
S^3RC test	91,57	0,9	0,988	0,91	0,896				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC train	100	100	100	100	100	100	100	100	100
S^3RC test	83,02	92,621	78,402	98,3	100	92,609	95,073	95,782	97,284
Clustering_Name: DBSCAN; Window_Size_7; Selected_Sample_Number_perClass_3									
	Acc.	Sens.	Spec.	F1score	Kappa				
S^3RC train	100	1	1	1	1				
S^3RC test	91,57	0,9	0,988	0,91	0,896				
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC train	100	100	100	100	100	100	100	100	100
S^3RC test	83,02	92,621	78,402	98,3	100	92,609	95,073	95,782	97,284

[illegible]

	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9
S^3RC_{train}	100	100	100	100	100	100	100	100	100
S^3RC_{test}	83,02	92,621	78,402	98,3	100	92,609	95,073	95,782	97,284

Tablo A.4 Indian Pines veri kümesi için farklı etiketli örnek sayıları ve farklı pencere boyutları için tüm etiketsiz örneklerin S^3RC ile detaylı sınıflama sonuçları

Clustering_Name: KMEANS; Window_Size_1; Selected_Sample_Number_perClass_1																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC_{train}	97,28	0,956	0,998	0,966	0,969											
S^3RC_{test}	87,94	0,853	0,991	0,873	0,867											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC_{train}	97,561	91,387	94,585	96,203	99,379	99,59	100	99,375	100	99,383	99,145	98,99	98,551	96,209	96,899	100
S^3RC_{test}	95,652	80,112	80,361	80,591	94,824	98,219	96,429	97,699	95	83,539	87,984	88,027	96,585	93,676	80,829	96,774
Clustering_Name: KMEANS; Window_Size_1; Selected_Sample_Number_perClass_3																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC_{train}	96,93	0,955	0,998	0,966	0,965											
S^3RC_{test}	87,68	0,848	0,991	0,87	0,864											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC_{train}	97,561	89,286	94,224	97,468	99,379	99,59	100	98,125	100	99,691	99,023	98,99	100	96,209	96,124	100
S^3RC_{test}	95,652	78,221	80,723	78,903	94,824	98,219	96,429	96,234	95	84,671	87,943	87,521	97,561	94,387	78,238	96,774
Clustering_Name: KMEANS; Window_Size_1; Selected_Sample_Number_perClass_5																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC_{train}	98,34	0,963	0,999	0,974	0,981											
S^3RC_{test}	88,67	0,854	0,992	0,877	0,875											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC_{train}	97,561	98,529	97,112	98,734	99,379	99,18	100	98,75	100	100	98,901	99,495	98,551	94,55	98,45	100
S^3RC_{test}	95,652	85,784	83,976	81,435	94,824	98,082	96,429	96,444	95	83,745	87,006	87,015	96,585	92,727	83,161	96,774
Clustering_Name: KMEANS; Window_Size_1; Selected_Sample_Number_perClass_15																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC_{train}	98,71	0,976	0,999	0,983	0,985											
S^3RC_{test}	88,73	0,867	0,992	0,885	0,875											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16

S^3RC_{train}	100	99,16	98,917	94,937	99,379	100	100	99,375	100	99,691	98,657	99,495	100	96,209	97,674	100
S^3RC_{test}	97,826	86,064	84,337	75,949	94,824	98,356	96,429	97,699	95	84,465	86,68	86,678	97,561	93,676	81,088	96,774
Clustering_Name: KMEANS; Window_Size_3; Selected_Sample_Number_perClass_1																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC_{train}	99,89	0,999	1	0,999	0,999											
S^3RC_{test}	95,63	0,959	0,997	0,958	0,951											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC_{train}	100	100	100	100	99,379	100	100	100	100	99,691	99,878	100	100	100	99,225	100
S^3RC_{test}	100	95,588	90,964	89,873	93,996	99,452	100	100	95	94,444	95,967	94,098	100	99,051	87,047	97,849
Clustering_Name: KMEANS; Window_Size_3; Selected_Sample_Number_perClass_3																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC_{train}	99,91	0,999	1	0,999	0,999											
S^3RC_{test}	95,63	0,958	0,997	0,958	0,951											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC_{train}	100	100	100	100	99,379	100	100	100	100	99,691	99,878	100	100	100	100	100
S^3RC_{test}	100	95,588	90,964	89,873	93,996	99,452	100	100	95	94,444	95,967	94,098	100	98,893	87,565	97,849
Clustering_Name: KMEANS; Window_Size_3; Selected_Sample_Number_perClass_5																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC_{train}	99,74	0,998	1	0,998	0,997											
S^3RC_{test}	95,57	0,962	0,997	0,96	0,95											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC_{train}	100	100	100	100	99,379	100	100	100	100	100	99,878	96,97	100	100	99,225	100
S^3RC_{test}	100	95,588	90,964	89,873	93,996	99,452	100	100	95	95,37	95,967	91,568	100	99,051	87,047	97,849
Clustering_Name: KMEANS; Window_Size_3; Selected_Sample_Number_perClass_15																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC_{train}	99,77	0,999	1	0,998	0,997											
S^3RC_{test}	95,66	0,962	0,997	0,96	0,951											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC_{train}	100	100	100	100	100	100	100	100	100	100	99,878	96,465	100	100	100	100

S^3RC_{test}	100	95,588	90,964	89,873	96,273	99,452	100	100	95	95,37	95,967	91,4	100	98,814	87,565	97,849
Clustering_Name: KMEANS; Window_Size_5; Selected_Sample_Number_perClass_1																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC_{train}	100	1	1	1	1											
S^3RC_{test}	97,32	0,968	0,998	0,974	0,97											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC_{train}	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100
S^3RC_{test}	100	93,487	95,422	96,624	98,551	99,589	100	99,582	100	97,119	98,778	93,761	100	99,209	95,078	100
Clustering_Name: KMEANS; Window_Size_5; Selected_Sample_Number_perClass_3																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC_{train}	100	1	1	1	1											
S^3RC_{test}	97,32	0,968	0,998	0,974	0,97											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC_{train}	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100
S^3RC_{test}	100	93,487	95,422	96,624	98,551	99,589	100	99,582	100	97,119	98,778	93,761	100	99,209	95,078	100
Clustering_Name: KMEANS; Window_Size_5; Selected_Sample_Number_perClass_5																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC_{train}	100	1	1	1	1											
S^3RC_{test}	97,32	0,968	0,998	0,974	0,97											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC_{train}	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100
S^3RC_{test}	100	93,487	95,422	96,624	98,551	99,589	100	99,582	100	97,119	98,778	93,761	100	99,209	95,078	100
Clustering_Name: KMEANS; Window_Size_5; Selected_Sample_Number_perClass_15																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC_{train}	100	1	1	1	1											
S^3RC_{test}	97,32	0,968	0,998	0,974	0,97											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC_{train}	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100
S^3RC_{test}	100	93,487	95,422	96,624	98,551	99,589	100	99,582	100	97,119	98,778	93,761	100	99,209	95,078	100

Clustering_Name: KMEANS; Window_Size_7; Selected_Sample_Number_perClass_1																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC_{train}	99,89	0,999	1	0,999	0,999											
S^3RC_{test}	97,7	0,98	0,998	0,98	0,974											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC_{train}	100	100	99,639	98,734	100	100	100	100	100	100	99,756	100	100	100	100	100
S^3RC_{test}	100	96,289	97,349	92,827	98,758	99,863	100	100	100	94,342	99,104	94,604	100	98,972	96,114	100
Clustering_Name: KMEANS; Window_Size_7; Selected_Sample_Number_perClass_3																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC_{train}	99,89	0,999	1	0,999	0,999											
S^3RC_{test}	97,91	0,978	0,999	0,98	0,976											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC_{train}	100	100	99,639	100	100	100	100	100	100	100	99,634	100	100	100	100	100
S^3RC_{test}	100	96,639	97,349	93,671	98,758	99,863	100	100	100	96,914	98,493	95,447	100	98,972	96,114	100
Clustering_Name: KMEANS; Window_Size_7; Selected_Sample_Number_perClass_5																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC_{train}	99,86	0,999	1	0,999	0,998											
S^3RC_{test}	97,91	0,978	0,999	0,98	0,976											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC_{train}	100	100	99,639	100	100	100	100	100	100	100	99,512	100	100	100	100	100
S^3RC_{test}	100	96,709	97,349	93,671	98,758	99,863	100	100	100	97,737	98,371	94,435	100	98,972	96,114	100
Clustering_Name: KMEANS; Window_Size_7; Selected_Sample_Number_perClass_15																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC_{train}	99,86	0,999	1	0,999	0,998											
S^3RC_{test}	97,83	0,978	0,998	0,98	0,975											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC_{train}	100	100	99,639	100	100	100	100	100	100	100	99,512	100	100	100	100	100
S^3RC_{test}	100	97,269	97,349	93,671	98,758	99,863	100	100	100	96,605	98,126	94,604	100	98,972	96,114	100
Clustering_Name: MEANSHIFT; Window_Size_1; Selected_Sample_Number_perClass_1																

[illegible]

[illegible]

S^3RC test	97,32	0,968	0,998	0,974	0,97											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC train	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100
S^3RC test	100	93,487	95,422	96,624	98,551	99,589	100	99,582	100	97,119	98,778	93,761	100	99,209	95,078	100
Clustering_Name: MEANSHIFT; Window_Size_5; Selected_Sample_Number_perClass_3																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC train	100	1	1	1	1											
S^3RC test	97,32	0,968	0,998	0,974	0,97											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC train	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100
S^3RC test	100	93,487	95,422	96,624	98,551	99,589	100	99,582	100	97,119	98,778	93,761	100	99,209	95,078	100
Clustering_Name: MEANSHIFT; Window_Size_5; Selected_Sample_Number_perClass_5																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC train	100	1	1	1	1											
S^3RC test	97,32	0,968	0,998	0,974	0,97											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC train	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100
S^3RC test	100	93,487	95,422	96,624	98,551	99,589	100	99,582	100	97,119	98,778	93,761	100	99,209	95,078	100
Clustering_Name: MEANSHIFT; Window_Size_5; Selected_Sample_Number_perClass_15																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC train	100	1	1	1	1											
S^3RC test	97,32	0,968	0,998	0,974	0,97											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC train	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100
S^3RC test	100	93,487	95,422	96,624	98,551	99,589	100	99,582	100	97,119	98,778	93,761	100	99,209	95,078	100
Clustering_Name: MEANSHIFT; Window_Size_7; Selected_Sample_Number_perClass_1																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC train	99,83	0,999	1	0,999	0,998											
S^3RC test	97,93	0,979	0,999	0,98	0,977											

[illegible]

	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC_{train}	97,561	89,916	83,755	68,354	99,379	99,59	100	98,75	100	98,765	99,145	98,485	98,551	95,735	97,674	100
S^3RC_{test}	95,652	79,272	73,373	51,477	94,824	98,219	96,429	96,444	95	82,51	89,532	86,509	96,585	93,597	79,534	96,774
Clustering_Name: SUBTRACTIVE; Window_Size_1; Selected_Sample_Number_perClass_3																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC_{train}	97,19	0,957	0,998	0,968	0,968											
S^3RC_{test}	87,71	0,851	0,991	0,872	0,864											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC_{train}	100	89,706	98,556	97,468	99,379	99,59	100	99,375	100	98,457	99,267	98,99	98,551	94,313	98,45	100
S^3RC_{test}	97,826	78,571	84,458	76,371	94,824	98,219	96,429	97,699	95	82,099	88,269	86,341	96,585	92,253	82,902	96,774
Clustering_Name: SUBTRACTIVE; Window_Size_1; Selected_Sample_Number_perClass_5																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC_{train}	98,45	0,969	0,999	0,977	0,983											
S^3RC_{test}	88,74	0,862	0,992	0,878	0,875											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC_{train}	100	98,319	98,917	97,468	99,379	99,59	100	98,75	100	98,765	99,023	98,99	98,551	96,209	95,349	100
S^3RC_{test}	97,826	85,574	86,024	75,527	94,824	98,219	96,429	96,444	95	81,276	87,821	86,341	96,585	95,336	77,979	96,774
Clustering_Name: SUBTRACTIVE; Window_Size_1; Selected_Sample_Number_perClass_15																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC_{train}	98,22	0,969	0,999	0,977	0,98											
S^3RC_{test}	88,59	0,859	0,992	0,878	0,874											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC_{train}	100	97,059	96,029	100	99,379	99,59	100	98,75	100	99,691	99,023	99,495	98,551	96,919	93,023	100
S^3RC_{test}	97,826	83,894	82,289	81,013	94,824	98,219	96,429	96,444	95	84,877	87,413	87,858	96,585	95,81	74,611	96,774
Clustering_Name: SUBTRACTIVE; Window_Size_3; Selected_Sample_Number_perClass_1																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC_{train}	99,89	0,999	1	0,999	0,999											
S^3RC_{test}	95,63	0,959	0,997	0,958	0,951											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16

[illegible]

S^3RC_{test}	100	93,487	95,422	96,624	98,551	99,589	100	99,582	100	97,119	98,778	93,761	100	99,209	95,078	100
Clustering_Name: SUBTRACTIVE; Window_Size_5; Selected_Sample_Number_perClass_3																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC_{train}	100	1	1	1	1											
S^3RC_{test}	97,32	0,968	0,998	0,974	0,97											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC_{train}	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100
S^3RC_{test}	100	93,487	95,422	96,624	98,551	99,589	100	99,582	100	97,119	98,778	93,761	100	99,209	95,078	100
Clustering_Name: SUBTRACTIVE; Window_Size_5; Selected_Sample_Number_perClass_5																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC_{train}	100	1	1	1	1											
S^3RC_{test}	97,32	0,968	0,998	0,974	0,97											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC_{train}	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100
S^3RC_{test}	100	93,487	95,422	96,624	98,551	99,589	100	99,582	100	97,119	98,778	93,761	100	99,209	95,078	100
Clustering_Name: SUBTRACTIVE; Window_Size_5; Selected_Sample_Number_perClass_15																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC_{train}	100	1	1	1	1											
S^3RC_{test}	97,32	0,968	0,998	0,974	0,97											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC_{train}	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100
S^3RC_{test}	100	93,487	95,422	96,624	98,551	99,589	100	99,582	100	97,119	98,778	93,761	100	99,209	95,078	100
Clustering_Name: SUBTRACTIVE; Window_Size_7; Selected_Sample_Number_perClass_1																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC_{train}	99,89	0,999	1	0,999	0,999											
S^3RC_{test}	97,7	0,98	0,998	0,98	0,974											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC_{train}	100	100	99,639	98,734	100	100	100	100	100	100	99,756	100	100	100	100	100
S^3RC_{test}	100	96,289	97,349	92,827	98,758	99,863	100	100	100	94,342	99,104	94,604	100	98,972	96,114	100

Clustering_Name: SUBTRACTIVE; Window_Size_7; Selected_Sample_Number_perClass_3																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC_{train}	99,89	0,999	1	0,999	0,999											
S^3RC_{test}	97,91	0,978	0,999	0,98	0,976											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC_{train}	100	100	99,639	100	100	100	100	100	100	100	99,634	100	100	100	100	100
S^3RC_{test}	100	96,639	97,349	93,671	98,758	99,863	100	100	100	96,914	98,493	95,447	100	98,972	96,114	100
Clustering_Name: SUBTRACTIVE; Window_Size_7; Selected_Sample_Number_perClass_5																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC_{train}	99,86	0,999	1	0,999	0,998											
S^3RC_{test}	97,91	0,978	0,999	0,98	0,976											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC_{train}	100	100	99,639	100	100	100	100	100	100	100	99,512	100	100	100	100	100
S^3RC_{test}	100	96,709	97,349	93,671	98,758	99,863	100	100	100	97,737	98,371	94,435	100	98,972	96,114	100
Clustering_Name: SUBTRACTIVE; Window_Size_7; Selected_Sample_Number_perClass_15																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC_{train}	99,86	0,999	1	0,999	0,998											
S^3RC_{test}	97,94	0,978	0,999	0,98	0,977											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC_{train}	100	100	99,639	100	100	100	100	100	100	100	99,512	100	100	100	100	100
S^3RC_{test}	100	96,639	97,349	93,671	98,758	99,863	100	100	100	97,531	98,371	95,447	100	98,972	96,114	100
Clustering_Name: KMEDOID; Window_Size_1; Selected_Sample_Number_perClass_1																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC_{train}	97,28	0,956	0,998	0,966	0,969											
S^3RC_{test}	87,94	0,853	0,991	0,873	0,867											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC_{train}	97,561	91,387	94,585	96,203	99,379	99,59	100	99,375	100	99,383	99,145	98,99	98,551	96,209	96,899	100
S^3RC_{test}	95,652	80,112	80,361	80,591	94,824	98,219	96,429	97,699	95	83,539	87,984	88,027	96,585	93,676	80,829	96,774
Clustering_Name: KMEDOID; Window_Size_1; Selected_Sample_Number_perClass_3																

[illegible]

S^3RC_{train}	99,89	0,999	1	0,999	0,999											
S^3RC_{test}	95,63	0,959	0,997	0,958	0,951											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC_{train}	100	100	100	100	99,379	100	100	100	100	99,691	99,878	100	100	100	99,225	100
S^3RC_{test}	100	95,588	90,964	89,873	93,996	99,452	100	100	95	94,444	95,967	94,098	100	99,051	87,047	97,849
Clustering_Name: KMEDOID; Window_Size_3; Selected_Sample_Number_perClass_5																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC_{train}	99,89	0,999	1	0,999	0,999											
S^3RC_{test}	95,63	0,959	0,997	0,958	0,951											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC_{train}	100	100	100	100	99,379	100	100	100	100	99,691	99,878	100	100	100	99,225	100
S^3RC_{test}	100	95,588	90,964	89,873	93,996	99,452	100	100	95	94,444	95,967	94,098	100	99,051	87,047	97,849
Clustering_Name: KMEDOID; Window_Size_3; Selected_Sample_Number_perClass_15																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC_{train}	99,91	0,999	1	0,999	0,999											
S^3RC_{test}	95,72	0,963	0,997	0,961	0,952											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC_{train}	100	100	100	100	100	100	100	100	100	100	99,878	98,99	100	100	100	100
S^3RC_{test}	100	95,588	90,964	89,873	96,273	99,452	100	100	95	95,165	95,967	92,749	100	98,814	87,565	97,849
Clustering_Name: KMEDOID; Window_Size_5; Selected_Sample_Number_perClass_1																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC_{train}	100	1	1	1	1											
S^3RC_{test}	97,32	0,968	0,998	0,974	0,97											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC_{train}	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100
S^3RC_{test}	100	93,487	95,422	96,624	98,551	99,589	100	99,582	100	97,119	98,778	93,761	100	99,209	95,078	100
Clustering_Name: KMEDOID; Window_Size_5; Selected_Sample_Number_perClass_3																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC_{train}	100	1	1	1	1											

S^3RC test	97,32	0,968	0,998	0,974	0,97											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC train	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100
S^3RC test	100	93,487	95,422	96,624	98,551	99,589	100	99,582	100	97,119	98,778	93,761	100	99,209	95,078	100
Clustering_Name: KMEDOID; Window_Size_5; Selected_Sample_Number_perClass_5																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC train	100	1	1	1	1											
S^3RC test	97,32	0,968	0,998	0,974	0,97											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC train	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100
S^3RC test	100	93,487	95,422	96,624	98,551	99,589	100	99,582	100	97,119	98,778	93,761	100	99,209	95,078	100
Clustering_Name: KMEDOID; Window_Size_5; Selected_Sample_Number_perClass_15																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC train	100	1	1	1	1											
S^3RC test	97,32	0,968	0,998	0,974	0,97											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC train	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100
S^3RC test	100	93,487	95,422	96,624	98,551	99,589	100	99,582	100	97,119	98,778	93,761	100	99,209	95,078	100
Clustering_Name: KMEDOID; Window_Size_7; Selected_Sample_Number_perClass_1																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC train	99,89	0,999	1	0,999	0,999											
S^3RC test	97,7	0,98	0,998	0,98	0,974											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC train	100	100	99,639	98,734	100	100	100	100	100	100	99,756	100	100	100	100	100
S^3RC test	100	96,289	97,349	92,827	98,758	99,863	100	100	100	94,342	99,104	94,604	100	98,972	96,114	100
Clustering_Name: KMEDOID; Window_Size_7; Selected_Sample_Number_perClass_3																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC train	99,86	0,999	1	0,999	0,998											
S^3RC test	97,93	0,979	0,999	0,981	0,977											

[illegible]

	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC_{train}	100	90,756	95,668	93,671	99,379	99,59	100	98,125	100	99,691	96,581	99,495	100	95,735	96,124	100
S^3RC_{test}	97,826	79,272	83,494	75,105	94,824	97,808	96,429	96,025	95	86,317	84,399	88,364	97,561	93,439	79,275	96,774
Clustering_Name: DBSCAN; Window_Size_1; Selected_Sample_Number_perClass_5																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC_{train}	95,81	0,952	0,997	0,964	0,953											
S^3RC_{test}	86,14	0,841	0,99	0,864	0,848											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC_{train}	100	95,168	98,556	93,671	99,379	99,59	100	98,125	100	100	89,255	100	100	95,972	96,899	100
S^3RC_{test}	97,826	83,543	84,458	68,776	94,824	97,808	96,429	96,025	95	87,963	76,293	89,882	97,561	93,913	80,57	96,774
Clustering_Name: DBSCAN; Window_Size_1; Selected_Sample_Number_perClass_15																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC_{train}	97,94	0,97	0,998	0,977	0,977											
S^3RC_{test}	88,39	0,864	0,992	0,881	0,872											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC_{train}	100	95,168	98,917	98,734	99,379	99,59	100	100	100	99,691	97,558	100	100	97,63	90,698	100
S^3RC_{test}	97,826	83,403	85,181	75,949	94,824	97,808	96,429	98,536	95	85,905	85,255	88,533	97,561	96,759	72,539	96,774
Clustering_Name: DBSCAN; Window_Size_3; Selected_Sample_Number_perClass_1																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC_{train}	99,89	0,999	1	0,999	0,999											
S^3RC_{test}	95,63	0,959	0,997	0,958	0,951											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC_{train}	100	100	100	100	99,379	100	100	100	100	99,691	99,878	100	100	100	99,225	100
S^3RC_{test}	100	95,588	90,964	89,873	93,996	99,452	100	100	95	94,444	95,967	94,098	100	99,051	87,047	97,849
Clustering_Name: DBSCAN; Window_Size_3; Selected_Sample_Number_perClass_3																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC_{train}	99,66	0,998	1	0,997	0,996											
S^3RC_{test}	95,53	0,961	0,997	0,959	0,95											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16

[illegible]

S^3RC_{test}	100	93,487	95,422	96,624	98,551	99,589	100	99,582	100	97,119	98,778	93,761	100	99,209	95,078	100
Clustering_Name: DBSCAN; Window_Size_5; Selected_Sample_Number_perClass_5																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC_{train}	100	1	1	1	1											
S^3RC_{test}	97,32	0,968	0,998	0,974	0,97											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC_{train}	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100
S^3RC_{test}	100	93,487	95,422	96,624	98,551	99,589	100	99,582	100	97,119	98,778	93,761	100	99,209	95,078	100
Clustering_Name: DBSCAN; Window_Size_5; Selected_Sample_Number_perClass_15																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC_{train}	100	1	1	1	1											
S^3RC_{test}	97,32	0,968	0,998	0,974	0,97											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC_{train}	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100
S^3RC_{test}	100	93,487	95,422	96,624	98,551	99,589	100	99,582	100	97,119	98,778	93,761	100	99,209	95,078	100
Clustering_Name: DBSCAN; Window_Size_7; Selected_Sample_Number_perClass_1																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC_{train}	99,89	0,999	1	0,999	0,999											
S^3RC_{test}	97,7	0,98	0,998	0,98	0,974											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC_{train}	100	100	99,639	98,734	100	100	100	100	100	100	99,756	100	100	100	100	100
S^3RC_{test}	100	96,289	97,349	92,827	98,758	99,863	100	100	100	94,342	99,104	94,604	100	98,972	96,114	100
Clustering_Name: DBSCAN; Window_Size_7; Selected_Sample_Number_perClass_3																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC_{train}	99,91	0,999	1	1	0,999											
S^3RC_{test}	97,85	0,979	0,998	0,98	0,976											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC_{train}	100	100	100	100	100	100	100	100	100	100	99,634	100	100	100	100	100
S^3RC_{test}	100	96,569	97,952	93,671	98,758	99,863	100	100	100	96,914	98,778	92,58	100	98,972	96,114	100

Clustering_Name: DBSCAN; Window_Size_7; Selected_Sample_Number_perClass_5																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC_{train}	99,97	1	1	1	1											
S^3RC_{test}	97,74	0,98	0,998	0,98	0,974											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC_{train}	100	100	100	100	100	100	100	100	100	100	99,878	100	100	100	100	100
S^3RC_{test}	100	96,569	97,831	93,671	98,758	99,863	100	100	100	94,65	99,226	92,58	100	98,972	96,114	100
Clustering_Name: DBSCAN; Window_Size_7; Selected_Sample_Number_perClass_15																
	Acc.	Sens.	Spec.	F1score	Kappa											
S^3RC_{train}	100	1	1	1	1											
S^3RC_{test}	97,71	0,98	0,998	0,98	0,974											
	Class1	Class2	Class3	Class4	Class5	Class6	Class7	Class8	Class9	Class10	Class11	Class12	Class13	Class14	Class15	Class16
S^3RC_{train}	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100
S^3RC_{test}	100	96,148	97,831	93,671	98,758	99,863	100	100	100	94,65	99,389	92,411	100	98,972	96,114	100

- [1] G. Bilgin, “Hiperspektral görüntülerin eğitici-siz bölütlenmesi,” PhD thesis, Yıldız Teknik Üniversitesi, 2009.
- [2] A. K. Jain, M. N. Murty, and P. J. Flynn, “Data clustering: A review,” *ACM computing surveys (CSUR)*, no. 3, pp. 264–323, 1999.
- [3] A. K. Jain, R. P. W. Duin, and J. Mao, “Statistical pattern recognition: A review,” *IEEE Transactions on pattern analysis and machine intelligence*, no. 1, pp. 4–37, 2000.
- [4] G. Hamerly and C. Elkan, “Alternatives to the k-means algorithm that find better clusterings,” in *Proceedings of the eleventh international conference on Information and knowledge management*, ACM, 2002, pp. 600–607.
- [5] G. Hamerly and C. Elkan, “Learning the k in k-means,” in *Advances in neural information processing systems*, 2004, pp. 281–288.
- [6] G. B. Coleman and H. C. Andrews, “Image segmentation by clustering,” *Proceedings of the IEEE*, no. 5, pp. 773–785, 1979.
- [7] A. K. Jain, “Data clustering: 50 years beyond k-means,” *Pattern recognition letters*, no. 8, pp. 651–666, 2010.
- [8] R. H. Turi, *Clustering-based colour image segmentation*. Monash University PhD thesis, 2001.
- [9] T. Kaukoranta, P. Franti, and O. Nevalainen, “A new iterative algorithm for vq codebook generation,” in *Proceedings 1998 International Conference on Image Processing. ICIP98 (Cat. No. 98CB36269)*, IEEE, 1998, pp. 589–593.
- [10] S. Baek, B. Jeon, D. Lee, and K.-M. Sung, “Fast clustering algorithm for vector quantisation,” *Electronics Letters*, no. 2, pp. 151–152, 1998.
- [11] Z. Xiang, “Color image quantization by minimizing the maximum intercluster distance,” *ACM Transactions on Graphics (TOG)*, no. 3, pp. 260–276, 1997.
- [12] D. Judd, P. K. McKinley, and A. K. Jain, “Large-scale parallel data clustering,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, no. 8, pp. 871–876, 1998.
- [13] H. M. Abbas and M. M. Fahmy, “Neural networks for maximum likelihood clustering,” *Signal Processing*, no. 1, pp. 111–126, 1994.
- [14] C. Carpineto and G. Romano, “A lattice conceptual clustering system and its application to browsing retrieval,” *Machine learning*, no. 2, pp. 95–122, 1996.
- [15] C.-Y. Lee and E. Antonsson, “Dynamic partitioned clustering using evolution strategies,” in *IEEE International Conference on Industrial Electronics, Control and Instrumentation*, IEEE, 2000, pp. 2716–2721.

- [16] H. Steinhaus, "Sur la division des corp materiels en parties," *Bull. Acad. Polon. Sci*, no. 1, pp. 801–804, 1956.
- [17] S. Lloyd, "Least squares quantization in pcm," *IEEE transactions on information theory*, no. 2, pp. 129–137, 1982.
- [18] A. Isodata, "Novel method of data analysis and pattern classification," *Menlo Park, CA: Standford Research Institute.*–1965.–365 p,
- [19] J. MacQueen *et al.*, "Some methods for classification and analysis of multivariate observations," in *Proceedings of the fifth Berkeley symposium on mathematical statistics and probability*, Oakland, CA, USA, 1967, pp. 281–297.
- [20] R. R. Yager and D. P. Filev, "Approximate clustering via the mountain method," *IEEE Transactions on Systems, Man, and Cybernetics*, no. 8, pp. 1279–1284, 1994.
- [21] S. Chiu, "Extracting fuzzy rules for pattern classification by cluster estimation," in *Proc. IFSA*, 1995, pp. 273–276.
- [22] R. P. Velthuizen, L. O. Hall, L. P. Clarke, and M. L. Silbiger, "An investigation of mountain method clustering for large data sets," *Pattern Recognition*, no. 7, pp. 1121–1135, 1997.
- [23] N. R. Pal and D. Chakraborty, "Mountain and subtractive clustering method: Improvements and generalizations," *International Journal of Intelligent Systems*, no. 4, pp. 329–341, 2000.
- [24] J. Yao, M. Dash, S. Tan, and H. Liu, "Entropy-based fuzzy clustering and fuzzy modeling," *Fuzzy sets and Systems*, no. 3, pp. 381–388, 2000.
- [25] R. O. Duda, P. E. Hart, and D. G. Stork, *Pattern classification*. John Wiley & Sons, 2012.
- [26] K. Fukunaga and L. Hostetler, "The estimation of the gradient of a density function, with applications in pattern recognition," *IEEE Transactions on Information Theory*, no. 1, pp. 32–40, 1975.
- [27] Y. Cheng, "Mean shift, mode seeking, and clustering," *IEEE transactions on pattern analysis and machine intelligence*, no. 8, pp. 790–799, 1995.
- [28] D. Comaniciu and P. Meer, "Mean shift: A robust approach toward feature space analysis," *IEEE Transactions on Pattern Analysis & Machine Intelligence*, no. 5, pp. 603–619, 2002.
- [29] D. Comaniciu, V. Ramesh, and P. Meer, "Kernel-based object tracking," *IEEE Transactions on Pattern Analysis & Machine Intelligence*, no. 5, pp. 564–575, 2003.
- [30] L. Kaufman and P. J. Rousseeuw, "Finding groups in data. an introduction to cluster analysis," *Wiley Series in Probability and Mathematical Statistics. Applied Probability and Statistics*, New York: Wiley, 1990, 1990.
- [31] J. Han, M. Kamber, and A. K. Tung, "Spatial clustering methods in data mining," *Geographic data mining and knowledge discovery*, pp. 188–217, 2001.
- [32] C. B. Lucasius, A. D. Dane, and G. Kateman, "On k-medoid clustering of large data sets with the aid of a genetic algorithm: Background, feasibility and comparison," *Analytica Chimica Acta*, no. 3, pp. 647–669, 1993.

- [33] C.-P. Wei, Y.-H. Lee, and C.-M. Hsu, "Empirical comparison of fast partitioning-based clustering algorithms for large data sets," *Expert Systems with applications*, no. 4, pp. 351–363, 2003.
- [34] R. T. Ng and J. Han, "Efficient and effective clustering methods for spatial data mining," in *Proceedings of VLDB*, 1994, pp. 144–155.
- [35] M. Ester, H.-P. Kriegel, J. Sander, X. Xu, *et al.*, "A density-based algorithm for discovering clusters in large spatial databases with noise.," in *Kdd*, 1996, pp. 226–231.
- [36] T. N. Tran, R. Wehrens, and L. M. Buydens, "Knn-kernel density-based clustering for high-dimensional multivariate data," *Computational Statistics & Data Analysis*, no. 2, pp. 513–525, 2006.
- [37] D. P. de Oliveira, J. H. Garrett Jr, and L. Soibelman, "A density-based spatial clustering approach for defining local indicators of drinking water distribution pipe breakage," *Advanced Engineering Informatics*, no. 2, pp. 380–389, 2011.
- [38] M. Daszykowski, B. Walczak, and D. Massart, "Looking for natural patterns in data: Part 1. density-based approach," *Chemometrics and Intelligent Laboratory Systems*, no. 2, pp. 83–92, 2001.
- [39] L. Zhou, P. K. Hopke, and P. Venkatachari, "Cluster analysis of single particle mass spectra measured at flushing, ny," *Analytica chimica acta*, no. 1, pp. 47–56, 2006.
- [40] W. Zhao, P. K. Hopke, and K. A. Prather, "Comparison of two cluster analysis methods using single particle mass spectra," *Atmospheric Environment*, no. 5, pp. 881–892, 2008.
- [41] S. Liu, Z.-T. Dou, F. Li, and Y.-L. Huang, "A new ant colony clustering algorithm based on dbscan," in *Proceedings of 2004 International Conference on Machine Learning and Cybernetics (IEEE Cat. No. 04EX826)*, IEEE, 2004, pp. 1491–1496.
- [42] A. Ghosh, A. Halder, M. Kothari, and S. Ghosh, "Aggregation pheromone density based data clustering," *Information Sciences*, no. 13, pp. 2816–2831, 2008.
- [43] C. Plant, S. J. Teipel, A. Oswald, C. Böhm, T. Meindl, J. Mourao-Miranda, A. W. Bokde, H. Hampel, and M. Ewers, "Automated detection of brain atrophy patterns based on mri for the prediction of alzheimer's disease," *Neuroimage*, no. 1, pp. 162–174, 2010.
- [44] M. E. Celebi, Y. A. Aslandogan, and P. R. Bergstresser, "Mining biomedical images with density-based clustering," in *International conference on information technology: coding and computing (ITCC'05)*, IEEE, 2005, pp. 163–168.
- [45] M. Mete, S. Kockara, and K. Aydin, "Fast density-based lesion detection in dermoscopy images," *Computerized Medical Imaging and Graphics*, no. 2, pp. 128–136, 2011.
- [46] J. Gong and C. H. Caldas, "Data processing for real-time construction site spatial modeling," *Automation in Construction*, no. 5, pp. 526–535, 2008.
- [47] V. Vapnik, *The nature of statistical learning theory*. Springer science & business media, 2013.

- [48] V. N. Vapnik, "Estimation of dependences based on empirical data," NY: Springer-Verlag, 1979.
- [49] C. Cortes and V. Vapnik, "Support-vector networks," *Machine learning*, no. 3, pp. 273–297, 1995.
- [50] C.-W. Hsu and C.-J. Lin, "A comparison of methods for multiclass support vector machines," *IEEE transactions on Neural Networks*, no. 2, pp. 415–425, 2002.
- [51] P. Schiilkop, C. Burgest, and V. Vapnik, "Extracting support data for a given task," in *Proceedings of the 1st international conference on knowledge discovery & data mining*, 1995, pp. 252–257.
- [52] V. Blanz, B. Schölkopf, H. Bülthoff, C. Burges, V. Vapnik, and T. Vetter, "Comparison of view-based object recognition algorithms using realistic 3d models," in *International Conference on Artificial Neural Networks*, Springer, 1996, pp. 251–256.
- [53] M. Schmidt, "Identifying speaker with support vector networks," in *www.stat.uga.edu/~lynne/symposium/paper1i3.ps.gz*, 1996.
- [54] E. Osuna, R. Freund, F. Girosi, *et al.*, "Training support vector machines: An application to face detection," in *cvpr*, 1997, p. 99.
- [55] T. Joachims, "Text categorization with support vector machines: Learning with many relevant features," in *European conference on machine learning*, Springer, 1998, pp. 137–142.
- [56] T. Joachims, "Transductive inference for text classification using support vector machines," in *International conference on Machine learning*, ACM, 1999, pp. 200–209.
- [57] O. Chapelle and A. Zien, "Semi-supervised classification by low density separation.," in *AISTATS*, Citeseer, 2005, pp. 57–64.
- [58] V. Sindhwani and S. S. Keerthi, "Large scale semi-supervised linear svms," in *Proceedings of the 29th annual international ACM SIGIR conference on Research and development in information retrieval*, ACM, 2006, pp. 477–484.
- [59] M. M. Adankon and M. Cheriet, "Learning semi-supervised svm with genetic algorithm," in *2007 International Joint Conference on Neural Networks*, IEEE, 2007, pp. 1825–1830.
- [60] Y. Chen, G. Wang, and S. Dong, "Learning with progressive transductive support vector machine," *Pattern Recognition Letters*, no. 12, pp. 1845–1855, 2003.
- [61] L. Bruzzone, M. Chi, and M. Marconcini, "A novel transductive svm for semisupervised classification of remote-sensing images," *IEEE Transactions on Geoscience and Remote Sensing*, no. 11, pp. 3363–3373, 2006.
- [62] X. J. Zhu, "Semi-supervised learning literature survey," University of Wisconsin-Madison Department of Computer Sciences, Tech. Rep., 2005.
- [63] W. Liao, A. Pizurica, W. Philips, and Y. Pi, "Feature extraction for hyperspectral images based on semi-supervised local discriminant analysis," in *2011 Joint Urban Remote Sensing Event*, IEEE, 2011, pp. 401–404.

- [64] S. Zhou, X. Zhang, J. Zhang, and H. Chen, "Spectral-spatial classification of hyperspectral image based on semi-supervised and level set methods," in *2012 IEEE International Geoscience and Remote Sensing Symposium*, IEEE, 2012, pp. 4279–4282.
- [65] M. Chi, J. Liu, J. Bao, and J. A. Benediktsson, "Scalable semi-supervised classification of hyperspectral remote sensing data with spectral and spatial information," in *2011 IEEE International Geoscience and Remote Sensing Symposium*, IEEE, 2011, pp. 1700–1703.
- [66] J. Li, J. M. Bioucas-Dias, and A. Plaza, "Semi-supervised discriminative random field for hyperspectral image classification," in *2012 4th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)*, IEEE, 2012, pp. 1–4.
- [67] Z. Guo, H. Yang, X. Bai, Z. Zhang, and J. Zhou, "Semi-supervised hyperspectral band selection via sparse linear regression and hypergraph models," in *2013 IEEE International Geoscience and Remote Sensing Symposium-IGARSS*, IEEE, 2013, pp. 1474–1477.
- [68] K. Uto, Y. Kosugi, and G. Saito, "Semi-supervised hyperspectral subspace learning based on a generalized eigenvalue problem for regression and dimensionality reduction," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, no. 6, pp. 2583–2599, 2014.
- [69] J. Xia, J. Chanussot, P. Du, and X. He, "Semi-supervised dimensionality reduction for hyperspectral remote sensing image classification," in *2012 4th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)*, IEEE, 2012, pp. 1–4.
- [70] L. Chen, R. Huang, and W. Huang, "Graph-based semi-supervised weighted band selection for classification of hyperspectral data," in *2010 International Conference on Audio, Language and Image Processing*, IEEE, 2010, pp. 1123–1126.
- [71] I. Dópido, J. Li, A. Plaza, and J. M. Bioucas-Dias, "A new semi-supervised approach for hyperspectral image classification with different active learning strategies," in *2012 4th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)*, IEEE, 2012, pp. 1–4.
- [72] J. Li, J. M. Bioucas-Dias, and A. Plaza, "Semi-supervised hyperspectral image classification using a new (soft) sparse multinomial logistic regression model," in *2011 3rd Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)*, IEEE, 2011, pp. 1–4.
- [73] O. Rajadell, P. Garcia-Sevilla, V. C. Dinh, and R. P. Duin, "Semi-supervised hyperspectral pixel classification using interactive labeling," in *2011 3rd Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)*, IEEE, 2011, pp. 1–4.
- [74] I. Dópido, J. Li, A. Plaza, and J. M. Bioucas-Dias, "Semi-supervised active learning for urban hyperspectral image classification," in *2012 IEEE International Geoscience and Remote Sensing Symposium*, IEEE, 2012, pp. 1586–1589.

- [75] W. Liao, R. Bellens, A. Pizurica, W. Philips, and Y. Pi, "Classification of hyperspectral data over urban areas using directional morphological profiles and semi-supervised feature extraction," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, no. 4, pp. 1177–1190, 2012.
- [76] M. Chi and L. Bruzzone, "Classification of hyperspectral data by continuation semi-supervised svm," in *2007 IEEE International Geoscience and Remote Sensing Symposium*, IEEE, 2007, pp. 3794–3797.
- [77] L. Gomez-Chova, J. Calpe, G. Camps-Valls, J. Martin, E. Soria, J. Vila, L. Alonso-Chorda, and J. Moreno, "Semi-supervised classification method for hyperspectral remote sensing images," in *International Geoscience and Remote Sensing Symposium*, 2003, pp. 1773–1776.
- [78] J. Li, A. Plaza, and J. M. Bioucas-Dias, "Integration of hyperspectral image classification and unmixing for active learning," in *2011 International Symposium on Image and Data Fusion*, IEEE, 2011, pp. 1–4.
- [79] H. Gao, M. K. Mandal, G. Guo, and J. Wan, "Semisupervised hyperspectral image classification with svm and pso," in *2010 International Conference on Measuring Technology and Mechatronics Automation*, IEEE, 2010, pp. 321–324.
- [80] E. Michaelsen, "Self-organizing maps for fusion of thermal hyperspectral-with high-resolution vis-data," in *2014 8th IAPR Workshop on Pattern Recognition in Remote Sensing*, IEEE, 2014, pp. 1–4.
- [81] D. Tuia and G. Camps-Valls, "Semisupervised remote sensing image classification with cluster kernels," *IEEE Geoscience and Remote Sensing Letters*, no. 2, pp. 224–228, 2009.
- [82] G. Camps-Valls, T. V. B. Marsheva, and D. Zhou, "Semi-supervised graph-based hyperspectral image classification," *IEEE transactions on Geoscience and Remote Sensing*, no. 10, pp. 3044–3054, 2007.
- [83] J. Li, J. M. Bioucas-Dias, and A. Plaza, "Semi-supervised hyperspectral image segmentation," in *2009 First Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing*, IEEE, 2009, pp. 1–4.
- [84] D. Tuia, J. Muñoz-Marí, and G. Camps-Valls, "Large scale semi-supervised image segmentation with active queries," in *2011 IEEE International Geoscience and Remote Sensing Symposium*, IEEE, 2011, pp. 2653–2656.
- [85] H. M. Adebajo and J. R. Tapamo, "Semi-supervised local feature extraction of hyperspectral images over urban areas," in *2013 International Conference on Adaptive Science and Technology*, IEEE, 2013, pp. 1–5.
- [86] J. Bai, S. Xiang, and C. Pan, "Classification oriented semi-supervised band selection for hyperspectral images," in *Proceedings of the 21st International Conference on Pattern Recognition (ICPR2012)*, IEEE, 2012, pp. 1888–1891.
- [87] H. Li, Y. Wang, J. Duan, S. Xiang, and C. Pan, "Group sparsity based semi-supervised band selection for hyperspectral images," in *2013 IEEE International Conference on Image Processing*, IEEE, 2013, pp. 3225–3229.
- [88] C. Senmao and W. Bo, "Application of semi-supervised dimensionality reduction for hyperspectral image classification," in *2010 International Conference on Computer Application and System Modeling (ICCASM 2010)*, IEEE, 2010, pp. 5–14.

- [89] M. He, X. Qu, and S. Mei, "A novel semi-supervised feature extraction algorithm," in *2011 6th IEEE Conference on Industrial Electronics and Applications*, IEEE, 2011, pp. 436–440.
- [90] J. M. R. Alves, J. M. Nascimento, J. M. Bioucas-Dias, A. Plaza, and V. Silva, "Parallel sparse unmixing of hyperspectral data," in *2013 IEEE International Geoscience and Remote Sensing Symposium-IGARSS*, IEEE, 2013, pp. 1446–1449.
- [91] C. Yang, S. Liu, L. Bruzzone, R. Guan, and P. Du, "A semisupervised feature metric based band selection method for hyperspectral image classification," in *2012 4th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)*, IEEE, 2012, pp. 1–4.
- [92] F. Melgani and L. Bruzzone, "Classification of hyperspectral remote sensing images with support vector machines," *IEEE Transactions on geoscience and remote sensing*, no. 8, pp. 1778–1790, 2004.
- [93] Z. Shao, L. Zhang, X. Zhou, and L. Ding, "A novel hierarchical semisupervised svm for classification of hyperspectral images," *IEEE Geoscience and Remote Sensing Letters*, no. 9, pp. 1609–1613, 2014.
- [94] J. Liu, Z. Wu, Z. Wei, L. Xiao, and L. Sun, "Spatial-spectral kernel sparse representation for hyperspectral image classification," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, no. 6, pp. 2462–2471, 2013.
- [95] S. Mallat, *A wavelet tour of signal processing*. Elsevier, 1999.
- [96] Y. Gao, J. Ma, and A. L. Yuille, "Semi-supervised sparse representation based classification for face recognition with insufficient labeled samples," *IEEE Transactions on Image Processing*, no. 5, pp. 2545–2560, 2017.
- [97] S. Gao, I. W.-H. Tsang, and L.-T. Chia, "Kernel sparse representation for image classification and face recognition," in *European Conference on Computer Vision*, Springer, 2010, pp. 1–14.
- [98] J. Wright, A. Y. Yang, A. Ganesh, S. S. Sastry, and Y. Ma, "Robust face recognition via sparse representation," *IEEE transactions on pattern analysis and machine intelligence*, no. 2, pp. 210–227, 2009.
- [99] J. Mairal, M. Elad, and G. Sapiro, "Sparse representation for color image restoration," *IEEE Transactions on image processing*, no. 1, pp. 53–69, 2008.
- [100] J. Yang, J. Wright, T. S. Huang, and Y. Ma, "Image super-resolution via sparse representation," *IEEE transactions on image processing*, no. 11, pp. 2861–2873, 2010.
- [101] S. Agarwal and D. Roth, "Learning a sparse representation for object detection," in *European conference on computer vision*, Springer, 2002, pp. 113–127.
- [102] X. Mei and H. Ling, "Robust visual tracking and vehicle classification via sparse representation," *IEEE transactions on pattern analysis and machine intelligence*, no. 11, pp. 2259–2272, 2011.

- [103] M. Elad and M. Aharon, "Image denoising via learned dictionaries and sparse representation," in *2006 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'06)*, IEEE, 2006, pp. 895–900.
- [104] J. M. Bioucas-Dias, A. Plaza, N. Dobigeon, M. Parente, Q. Du, P. Gader, and J. Chanussot, "Hyperspectral unmixing overview: Geometrical, statistical, and sparse regression-based approaches," *IEEE journal of selected topics in applied earth observations and remote sensing*, no. 2, pp. 354–379, 2012.
- [105] M.-D. Iordache, J. M. Bioucas-Dias, and A. Plaza, "Sparse unmixing of hyperspectral data," *IEEE Transactions on Geoscience and Remote Sensing*, no. 6, pp. 2014–2039, 2011.
- [106] S. Li and H. Qi, "Sparse representation based band selection for hyperspectral images," in *2011 18th IEEE International Conference on Image Processing*, IEEE, 2011, pp. 2693–2696.
- [107] W. Sun, L. Zhang, B. Du, W. Li, and Y. M. Lai, "Band selection using improved sparse subspace clustering for hyperspectral imagery classification," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, no. 6, pp. 2784–2797, 2015.
- [108] Y. Chen, N. M. Nasrabadi, and T. D. Tran, "Sparse representation for target detection in hyperspectral imagery," *IEEE Journal of Selected Topics in Signal Processing*, no. 3, pp. 629–640, 2011.
- [109] Y.-Q. Zhao and J. Yang, "Hyperspectral image denoising via sparse representation and low-rank constraint," *IEEE Transactions on Geoscience and Remote Sensing*, no. 1, pp. 296–308, 2015.
- [110] Y. Qian and M. Ye, "Hyperspectral imagery restoration using nonlocal spectral-spatial structured sparse representation with noise estimation," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, no. 2, pp. 499–515, 2013.
- [111] W. Dong, F. Fu, G. Shi, X. Cao, J. Wu, G. Li, and X. Li, "Hyperspectral image super-resolution via non-negative structured sparse representation," *IEEE Transactions on Image Processing*, no. 5, pp. 2337–2352, 2016.
- [112] W. Du, W. Qiang, M. Lv, Q. Hou, L. Zhen, and L. Jing, "Semi-supervised dimension reduction based on hypergraph embedding for hyperspectral images," *International Journal of Remote Sensing*, no. 6, pp. 1696–1712, 2018.
- [113] T. Qiao, Z. Yang, J. Ren, P. Yuen, H. Zhao, G. Sun, S. Marshall, and J. A. Benediktsson, "Joint bilateral filtering and spectral similarity-based sparse representation: A generic framework for effective feature extraction and data classification in hyperspectral imaging," *Pattern Recognition*, pp. 316–328, 2018.
- [114] Y. Chen, N. M. Nasrabadi, and T. D. Tran, "Hyperspectral image classification using dictionary-based sparse representation," *IEEE transactions on geoscience and remote sensing*, no. 10, pp. 3973–3985, 2011.
- [115] Y. Chen, N. M. Nasrabadi, and T. D. Tran, "Hyperspectral image classification via kernel sparse representation," *IEEE Transactions on Geoscience and Remote sensing*, no. 1, pp. 217–231, 2013.

- [116] S. Ren, S. Wan, X. Gu, P. Yuan, and H. Xu, "Semi-supervised hyperspectral image classification using local low-rank representation," *Remote Sensing Letters*, no. 2, pp. 195–204,
- [117] S. Samiappan and R. J. Moorhead, "Semi-supervised co-training and active learning framework for hyperspectral image classification," in *IEEE Int. Geoscience and Remote Sensing Symposium, IGARSS'15*, 2015, pp. 401–404.
- [118] H. Alhichri, Y. Bazi, N. Alajlan, and N. Ammour, "A hierarchical learning paradigm for semi-supervised classification of remote sensing images," in *IEEE Int. Geoscience and Remote Sensing Symposium, IGARSS'15*, 2015, pp. 4388–4391.
- [119] Y. LeCun, L. Bottou, Y. Bengio, P. Haffner, *et al.*, "Gradient-based learning applied to document recognition," *Proceedings of the IEEE*, no. 11, pp. 2278–2324, 1998.
- [120] G. E. Hinton, S. Osindero, and Y.-W. Teh, "A fast learning algorithm for deep belief nets," *Neural computation*, no. 7, pp. 1527–1554, 2006.
- [121] Y. Liu, G. Cao, Q. Sun, and M. Siegel, "Hyperspectral classification via deep networks and superpixel segmentation," *International Journal of Remote Sensing*, no. 13, pp. 3459–3482, 2015.
- [122] J. Yue, W. Zhao, S. Mao, and H. Liu, "Spectral–spatial classification of hyperspectral images using deep convolutional neural networks," *Remote Sensing Letters*, no. 6, pp. 468–477, 2015.
- [123] Y. Chen, Z. Lin, X. Zhao, G. Wang, and Y. Gu, "Deep learning-based classification of hyperspectral data," *IEEE Journal of Selected topics in applied earth observations and remote sensing*, no. 6, pp. 2094–2107, 2014.
- [124] F. I. Alam, J. Zhou, A. W.-C. Liew, and X. Jia, "CRF learning with CNN features for hyperspectral image segmentation," in *IEEE Int. Geoscience and Remote Sensing Symposium, IGARSS'16*, 2016, pp. 6890–6893.
- [125] W. Zhao and S. Du, "Spectral–spatial feature extraction for hyperspectral image classification: A dimension reduction and deep learning approach," *IEEE Transactions on Geoscience and Remote Sensing*, no. 8, pp. 4544–4554, 2016.
- [126] W. Zhao, Z. Guo, J. Yue, X. Zhang, and L. Luo, "On combining multiscale deep learning features for the classification of hyperspectral remote sensing imagery," *International Journal of Remote Sensing*, no. 13, pp. 3368–3379, 2015.
- [127] F. Xie, C. Lei, F. Li, D. Huang, and J. Yang, "Unsupervised hyperspectral feature selection based on fuzzy c-means and grey wolf optimizer," *International Journal of Remote Sensing*, pp. 1–24, 2018.
- [128] Y. Chen, H. Jiang, C. Li, X. Jia, and P. Ghamisi, "Deep feature extraction and classification of hyperspectral images based on convolutional neural networks," *IEEE Transactions on Geoscience and Remote Sensing*, no. 10, pp. 6232–6251, 2016.
- [129] A. Romero, C. Gatta, and G. Camps-Valls, "Unsupervised deep feature extraction for remote sensing image classification," *IEEE Transactions on Geoscience and Remote Sensing*, no. 3, pp. 1349–1362, 2016.

- [130] A. Krizhevsky, I. Sutskever, and G. E. Hinton, “Imagenet classification with deep convolutional neural networks,” in *Advances in neural information processing systems*, 2012, pp. 1097–1105.
- [131] S. Ren, K. He, R. Girshick, and J. Sun, “Faster r-cnn: Towards real-time object detection with region proposal networks,” in *Advances in neural information processing systems*, 2015, pp. 91–99.
- [132] R. Kiros, R. Salakhutdinov, and R. S. Zemel, “Unifying visual-semantic embeddings with multimodal neural language models,” *arXiv preprint arXiv:1411.2539*, 2014.
- [133] J. Mao, W. Xu, Y. Yang, J. Wang, and A. L. Yuille, “Explain images with multimodal recurrent neural networks,” *arXiv preprint arXiv:1410.1090*, 2014.
- [134] J. Donahue, L. Anne Hendricks, S. Guadarrama, M. Rohrbach, S. Venugopalan, K. Saenko, and T. Darrell, “Long-term recurrent convolutional networks for visual recognition and description,” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2015, pp. 2625–2634.
- [135] S. Antol, A. Agrawal, J. Lu, M. Mitchell, D. Batra, C. Lawrence Zitnick, and D. Parikh, “Vqa: Visual question answering,” in *Proceedings of the IEEE international conference on computer vision*, 2015, pp. 2425–2433.
- [136] P. Sermanet, D. Eigen, X. Zhang, M. Mathieu, R. Fergus, and Y. LeCun, “Overfeat: Integrated recognition, localization and detection using convolutional networks,” *arXiv preprint arXiv:1312.6229*, 2013.
- [137] R. Stewart, M. Andriluka, and A. Y. Ng, “End-to-end people detection in crowded scenes,” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 2325–2333.
- [138] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, “You only look once: Unified, real-time object detection,” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 779–788.
- [139] S. Ji, W. Xu, M. Yang, and K. Yu, “3d convolutional neural networks for human action recognition,” *IEEE transactions on pattern analysis and machine intelligence*, no. 1, pp. 221–231, 2013.
- [140] G. Lin, C. Shen, A. Van Den Hengel, and I. Reid, “Efficient piecewise training of deep structured models for semantic segmentation,” in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2016, pp. 3194–3203.
- [141] O. M. Parkhi, A. Vedaldi, A. Zisserman, *et al.*, “Deep face recognition,” in *bmvc*, 2015, pp. 6–17.
- [142] Y. Sun, X. Wang, and X. Tang, “Deep learning face representation from predicting 10,000 classes,” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2014, pp. 1891–1898.
- [143] G. Levi and T. Hassner, “Age and gender classification using convolutional neural networks,” in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*, 2015, pp. 34–42.

- [144] K. Makantasis, K. Karantzalos, A. Doulamis, and N. Doulamis, "Deep supervised learning for hyperspectral data classification through convolutional neural networks," in *2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, IEEE, 2015, pp. 4959–4962.
- [145] Q. Zou, L. Ni, T. Zhang, and Q. Wang, "Deep learning based feature selection for remote sensing scene classification," *IEEE Geoscience and Remote Sensing Letters*, no. 11, pp. 2321–2325, 2015.
- [146] E. Othman, Y. Bazi, H. AlHichri, and N. Alajlan, "A deep learning approach for unsupervised domain adaptation in multitemporal remote sensing images," in *2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, IEEE, 2015, pp. 2401–2404.
- [147] M. A. Veganzones, G. Tochon, M. Dalla Mura, A. J. Plaza, and J. Chanussot, "A comparison study between windowing and binary partition trees for hyperspectral image information mining," in *2013 IEEE International Geoscience and Remote Sensing Symposium-IGARSS*, IEEE, 2013, pp. 4375–4378.
- [148] J.-M. Yang, B.-C. Kuo, P.-T. Yu, and C.-H. Chuang, "A dynamic subspace method for hyperspectral image classification," *IEEE Transactions on Geoscience and Remote Sensing*, no. 7, pp. 2840–2853, 2010.
- [149] Y. Tarabalka, J. Chanussot, and J. A. Benediktsson, "Segmentation and classification of hyperspectral images using watershed transformation," *Pattern Recognition*, no. 7, pp. 2367–2379, 2010.
- [150] A. Amankwah, "Spatial mutual information based hyperspectral band selection for classification," *The Scientific World Journal*, 2015.
- [151] P. Drineas, A. Frieze, R. Kannan, S. Vempala, and V. Vinay, "Clustering large graphs via the singular value decomposition," *Machine learning*, no. 1-3, pp. 9–33, 2004.
- [152] M. Meilä, "The uniqueness of a good optimum for k-means," in *Proceedings of the 23rd international conference on Machine learning*, ACM, 2006, pp. 625–632.
- [153] H. Binol, G. Bilgin, S. Dinc, and A. Bal, "Kernel fukunaga-koontz transform subspaces for classification of hyperspectral images with small sample sizes," *IEEE Geoscience and Remote Sensing Letters*, no. 6, pp. 1287–1291, 2015.
- [154] D. J. Im and G. W. Taylor, "Semisupervised hyperspectral image classification via neighborhood graph learning," *IEEE Geoscience and Remote Sensing Letters*, no. 9, pp. 1913–1917, 2015.
- [155] L. Ma, A. Ma, C. Ju, and X. Li, "Graph-based semi-supervised learning for spectral-spatial hyperspectral image classification," *Pattern Recognition Letters*, 2016.
- [156] R. Ji, Y. Gao, R. Hong, Q. Liu, D. Tao, and X. Li, "Spectral-spatial constraint hyperspectral image classification," *IEEE Transactions on Geoscience and Remote Sensing*, no. 3, pp. 1811–1824, 2014.
- [157] L. Wang, S. Hao, Y. Wang, Y. Lin, and Q. Wang, "Spatial-spectral information-based semisupervised classification algorithm for hyperspectral imagery," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, no. 8, pp. 3577–3585, 2014.

İletişim Bilgileri: aydemir.said@gmail.com

Makaleler

1. **Aydemir, M. Said**, and Gokhan Bilgin. "Semisupervised Hyperspectral Image Classification Using Small Sample Sizes." IEEE Geoscience and Remote Sensing Letters 14.5 (2017): 621-625.
2. **Aydemir, M. Said**, and Gokhan Bilgin. "Semisupervised Hyperspectral Image Classification Using Deep Features." IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, (2019-Accepted).
3. **Aydemir, M. Said**, and Gokhan Bilgin. "Semi-Supervised Sparse Representation Classifier (S^3RC) with Deep Features on Small Sample Sized Hyperspectral Images." Elsevier Neurocomputing, (2019-In Revision).

Konferans Bildirileri

1. **Aydemir, M. Said**, and Gokhan Bilgin. "Graph-based semi-supervised learning with GPU on small sample sized hyperspectral images." 2017 25th Signal Processing and Communications Applications Conference (SIU). IEEE, 2017.
2. **Aydemir, M. Said**, and Gokhan Bilgin. "Semi-supervised classification of hyperspectral images with small sample sizes." 2016 24th Signal Processing and Communication Application Conference (SIU). IEEE, 2016.
3. **Aydemir, M. Said**, and Gökhan Bilgin. "Combination of sparse and semi-supervised learning for classification of hyperspectral images." 2015 23rd Signal Processing and Communications Applications Conference (SIU). IEEE, 2015.
4. **Aydemir, M. Said**, and Gökhan Bilgin. "2D2 PCA-based hyperspectral image classification with utilization of spatial information." 2013 5th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS). IEEE, 2013.

Proje

1. "Hiperspektral Görüntülerde Yarı Güdümlü Öğrenme Teknikleri", BAP Doktora, 2016-04-01-DOP02, Araştırmacı, 2019.