

**HİPERSPEKTRAL GÖRÜNTÜLER İÇİN
SPEKTRAL-UZAMSAL EN YAKIN ALTUZAY
SINIFLANDIRICILARI**

**SPECTRAL-SPATIAL NEAREST SUBSPACE CLASSIFIERS
FOR HYPERPECTRAL IMAGES**

KEMAL GÜRKAN TOKER

DOÇ. DR. SENİHA ESEN YÜKSEL ERDEM

Tez Danışmanı


Hacettepe Üniversitesi

Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğinin

Elektrik ve Elektronik Mühendisliği Anabilim Dalı için Öngördüğü

DOKTORA TEZİ olarak hazırlanmıştır.

2023



Annem, babam ve Elmas'a...

ÖZET

HİPERSPEKTRAL GÖRÜNTÜLER İÇİN SPEKTRAL-UZAMSAL EN YAKIN ALTUZAY SINIFLANDIRICILARI

Kemal Gürkan TOKER

Doktora, Elektrik ve Elektronik Mühendisliği Bölümü

Tez Danışmanı: Doç. Dr. Seniha Esen Yüksel Erdem

Ocak 2023, 131 sayfa

Bu tez kapsamında hiperspektral görüntü sınıflandırma için spektral ve uzamsal bilgiden etkili bir şekilde yararlanan en yakın altuzay sınıflandırıcıları önerilmiştir. Önerilen yöntemlerde En Yakın Altuzay Sınıflandırıcısı (Nearest Subspace Classifier, NSC) yönteminin geometrik yorumundan ilham alınmıştır. NSC, aynı sınıftan örneklerin yaklaşık olarak aynı altuzayda olması gerektiği varsayımıyla çalışan basit bir sınıflandırıcıdır. Bu varsayıma dayanarak, NSC yöntemi, test örneği ile sınıf içi eğitim örneklerinin kapsadığı altuzay arasındaki yakınlığı analiz eder ve test örneğinin etiketini en yakın altuzayın ait olduğu sınıfa atar. Fakat, NSC sadece spektral bilgiyi dikkate alır ve sınıflandırma sırasında uzamsal bilgiden yararlanmaz. Tez kapsamında NSC yönteminin dayandığı varsayım genişletilmiş ve uzamsal olarak bitişik piksellerin de büyük olasılıkla aynı sınıfa ait olduğu varsayımı eklenmiştir. Bu iki varsayım birleştirilerek, uzamsal olarak bitişik piksellerin de yaklaşık olarak aynı altuzayda bulunması gerektiği sonucuna varılmıştır. Bu varsayımlara dayanarak sınıflandırma sırasında uzamsal bilgiden yararlanmak için kullanılan pikseller kümesinin kapsadığı altuzay ile sınıf içi eğitim örneklerinin kapsadığı altuzay arasındaki yakınlığı analiz ederek sınıflandırma işlemi yapan Spektral-Uzamsal En Yakın Altuzay Sınıflandırıcısı

yaklaşımı önerilmiştir. Altuzaylar arasındaki yakınlığı ölçmek için tez kapsamında Kanonik Korelasyon Analizi yönteminden yararlanılmıştır.

Bu tez kapsamında, Spektral-Uzamsal En Yakın Altuzay Sınıflandırıcısı yaklaşımını kullanan dört farklı yöntem geliştirilmiştir. Bu yöntemler uzamsal bilgiyi kullanma şekillerine göre birbirlerinden ayrılmaktadır. Geliştirilen yöntemlerden ilki, test pikseli komşuluğunda yer alan uzamsal bir pencereden yararlanırken, diğer üç yöntem süperpiksellere yararlanmaktadır. Geliştirilen yöntemler literatürde yaygın olarak kullanılan veri kümelerinin yanı sıra müsilaaj veri kümeleri üzerinde de test edilmiştir.

Önerilen sınıflandırma yaklaşımının avantajları; (i) anlamlı ve anlaşılması kolay bir geometrik yorumunun olması, (ii) uzun eğitim sürelerine ihtiyaç duymaması, (iii) kapalı-form bir çözümünün olması, (iv) test etmesinin basit olması ve zahmetli parametre ayarlama süreçleri gerektirmemesi, (v) az sayıda etiketli veri olduğu durumlarda iyi sonuçlar vermesi, (vi) gürültülü ve aykırı piksellere karşı dayanıklı olmasıdır.

Anahtar Kelimeler: Hiperspektral Görüntü Sınıflandırma, En Yakın Altuzay Sınıflandırıcısı, Kanonik Korelasyon Analizi, Gösterim Tabanlı Yöntemler, Müsilaaj Tespiti

ABSTRACT

SPECTRAL-SPATIAL NEAREST SUBSPACE CLASSIFIERS FOR HYPERSPPECTRAL IMAGES

Kemal Gürkan TOKER

Doctor of Philosophy, Electrical and Electronics Engineering Department

Supervisor: Assoc. Prof. Dr. Seniha Esen Yüksel Erdem

January 2023, 131 pages

The nearest subspace classifiers that make effective use of spectral and spatial information for hyperspectral image classification are proposed within the scope of this thesis. The methods are proposed, inspired by the geometric interpretation of the nearest subspace classifier method. Nearest Subspace Classifier (NSC) is a simple classifier that works on the assumption that samples from the same class approximately lie on the same subspace. Based on this assumption, NSC method analyzes the closeness between the test sample and the space spanned by the within-class training samples. Then, the label of test sample is assigned to the closest class. However, NSC only considers the spectral information and neglects the spatial information. In addition to the assumption in the NSC method, we add another assumption that spatially adjacent pixels quite likely belong to the same class. By combining these two assumptions, we conclude that spatially adjacent pixels must approximately lie on the same subspace as well. Based on these assumptions, we propose the spectral-spatial nearest subspace classification (SSNSC) approach as a generic classification framework that performs classification by analyzing the closeness between the subspace spanned by the samples used for spatial information and subspace spanned by the within-class training samples. In this

thesis, Canonical Correlation Analysis is used to measure the closeness between these two subspaces.

In this thesis, we developed four different methods that are specialized versions of the SSNSC approach. They differ from each other based on how they utilize spatial information. The first one uses spatial window as spatial information, and other three use superpixels. The methods are tested on the mucilage datasets as well as the datasets commonly used in the literature.

The strength of the proposed classification approach is that i) the geometric interpretation of the proposed approach is meaningful and easy to understand, ii) it does not need long training times, (iii) it has a closed-form solution, (iv) it is simple to test and does not require laborious parameter-tuning processes, (v) it outperforms the existing solutions when the number of labelled training samples is scarce, vi) it is robust to noisy and outlier pixels.

Keywords: Hyperspectral Image Classification, Nearest Subspace Classifier, Canonical Correlation Analysis, Representation-Based Methods, Mucilage Detection

TEŞEKKÜR

Doktora eğitimim boyunca bilgi ve deneyimleri ile bana yol gösteren çok değerli tez danışmanım Sayın Doç. Dr. Seniha Esen YÜKSEL ERDEM'e,

Tez sürecinde deneyimleri ve farklı bakış açıları ile tezimin daha iyi olması için katkıda bulunan değerli hocalarım Prof. Dr. Aydın ALATAN'a ve Dr. Yakup ÖZKAZANÇ'a,

Tez jürisinde yer alan ve önerilerini paylaşan değerli hocalarım Prof. Dr. Gözde BOZDAĞI AKAR ve Dr. Şölen KUMBAY YILDIZ'a,

Hayatım boyunca desteklerini esirgemeyip bugünlere gelmemi sağlayan annem Birgül TOKER ve babam Mehmet Ergün TOKER'e,

Bu zorlu süreçte desteğini ve anlayışını eksik etmeyen eşim Elmas TOKER'e,

Doktora sürecinde her türlü kolaylığı sağlayan ASELSAN A.Ş. ailesine,

121G085 numaralı proje kapsamında bu tez çalışmasına desteklerinden dolayı TÜBİTAK'a, teşekkürlerimi sunarım.

Kemal Gürkan TOKER

Ocak 2023, Ankara

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	i
ABSTRACT	iii
TEŞEKKÜR	v
İÇERİK	vi
TABLolar	x
ŞEKİLLER	xvi
SİMGELER VE KISALTMALAR	xvii
1. GİRİŞ	1
1.1. Hiperspektral Görüntü	2
1.2. Hiperspektral Görüntü Sınıflandırma	6
1.3. Tezin Amacı	13
1.4. Tez Çalışmasının Katkıları	14
1.5. Tezin Akışı	16
2. GÖSTERİM TABANLI YÖNTEMLER	17
2.1. Notasyon	17
2.2. Seyrek Gösterim Tabanlı Sınıflandırıcı (SRC)	19
2.3. İşbirlikçi Gösterim Tabanlı Sınıflandırıcı (CRC)	21
2.4. En Yakın Altuzay Sınıflandırıcısı (NSC)	22
2.5. Literatürde Yer Alan Uzamsal Bilgiden Yararlanan NSC Yöntemleri	25
2.5.1. Ortak En Yakın Altuzay Sınıflandırıcısı	25
2.5.2. Dayanıkl Ortak En Yakın Altuzay Sınıflandırıcısı	27
2.5.3. Uzamsal Bilgiyi Kullanan Diğer NSC tabanlı yöntemler	29
3. ÖNERİLEN YÖNTEMLER	30
3.1. Motivasyon	30
3.2. Kanonik Korelasyon Analizi (CCA)	34
3.3. Spektral-Uzamsal En Yakın Altuzay Sınıflandırıcıları	38
3.3.1. Pencere Tabanlı En Yakın Altuzay Sınıflandırıcısı (WBNSC)	40

3.3.2. Süperpiksel Tabanlı En Yakın Altuzay Sınıflandırıcısı (SBNSC)	42
3.3.3. Çok-Ölçekli Süperpiksel Tabanlı En Yakın Altuzay Sınıflandırıcısı (MS-BNSC)	45
3.3.4. Çoğunluk Oylama ile Süperpiksel Tabanlı En Yakın Altuzay Sınıflandırıcısı (SBNSCMV)	47
4. DENEYSEL ÇALIŞMALAR	50
4.1. Veri Kümeleri	51
4.1.1. Literatürde Yaygın Olarak Kullanılan Veri Kümeleri	51
4.1.2. Müsilaj Veri Kümeleri	55
4.2. Sentetik Veriler ile Yapılan Deneyler Üzerinde Önerilen SSNSC Yaklaşımının Çalışma Mekanizmasının İncelenmesi	59
4.3. WBNSC Yöntemi için Yapılan Deneyler.....	64
4.3.1. Parametre Düzenleme.....	65
4.3.2. Salinas Veri Kümesi ile Yapılan Deneyler	70
4.3.3. Indian Pines Verisi ile Yapılan Deneyler.....	73
4.3.4. Botswana Verisi ile Yapılan Deneyler.....	75
4.3.5. Eğitim Örneği Sayısının Yöntemlerin Sınıflandırma Performansına Etkisi .	77
4.3.6. Yöntemlerin Hesaplama Karmaşıklığının Analizi.....	79
4.4. Önerilen Süperpiksel Tabanlı Yöntemler için Yapılan Deneyler	81
4.4.1. Parametre Düzenleme.....	82
4.4.2. Önerilen Yöntemlerin Karşılaştırmalı Analizi	82
4.4.3. Salinas Veri Kümesi ile Yapılan Deneyler	86
4.4.4. Indian Pines Veri Kümesi ile Yapılan Deneyler	90
4.4.5. Eğitim Örneği Sayısının Yöntemlerin Sınıflandırma Performansına Etkisi .	91
4.5. Müsilaj Tespiti Deneyleri	93
4.5.1. Parametre Düzenleme.....	95
4.5.2. İstanbul Müsilaj Verisi ile Yapılan Deneyler	95
4.5.3. Bursa Müsilaj Verisi ile Yapılan Deneyler	98
4.5.4. Bursa Veri Kümesinden Alınan Eğitim Verilerinin İstanbul Veri Kümesi Üzerinde Test Edilmesi	101

4.5.5. İstanbul Veri Kümesinden Alınan Eğitim Verilerinin Bursa Veri Kümesi Üzerinde Test Edilmesi	103
4.5.6. Yöntemlerin Hesaplama Karmaşıklığının Analizi.....	105
5. SONUÇLAR VE TARTIŞMA	107
6. KAYNAKLAR	111



TABLÖLAR

	<u>Sayfa</u>
Tablo 1.1 Elektromanyetik spektrumun optik bölgesi için dalgaboyu bilgileri	4
Tablo 2.1 Literatürde yer alan uzamsal bilgiyi kullanan NSC tabanlı yöntemlerin eksiklikleri.....	29
Tablo 4.1 Deneyler sırasında kullanılan veri kümelerine ait bilgiler	51
Tablo 4.2 Indian Pines veri kümesi etiketli örnek bilgileri	52
Tablo 4.3 Salinas veri kümesi etiketli örnek bilgileri.....	53
Tablo 4.4 Botswana veri kümesi etiketli örnek bilgileri.....	55
Tablo 4.5 İstanbul veri kümesi etiketli örnek bilgileri.....	57
Tablo 4.6 Bursa veri kümesi etiketli örnek bilgileri	58
Tablo 4.7 Önerilen WBNSC yönteminin farklı pencere boyutları için sınıflandırma performansları.....	66
Tablo 4.8 Salinas verisi için önerilen WBNSC yöntemi ve karşılaştırılan diğer yöntemlerin sınıflandırma doğrulukları (%)	72
Tablo 4.9 Indian Pines verisi için önerilen WBNSC yöntemi ve karşılaştırılan diğer yöntemlerin sınıflandırma doğrulukları (%).....	75
Tablo 4.10 Botswana verisi için önerilen WBNSC yöntemi ve karşılaştırılan diğer yöntemlerin sınıflandırma doğrulukları (%).....	77
Tablo 4.11 Salinas, Indian Pines, Botswana veri kümeleri için yöntemlerin ortalama yürütme süreleri (saniye cinsinden)	80
Tablo 4.12 Değişen pencere boyutu, eğitim verisi sayısı, test verisi sayısı, bant sayısı ve sınıf sayısına göre önerilen WBNSC yönteminin yürütme süreleri (saniye cinsinden)	81
Tablo 4.13 Salinas verisi için önerilen yöntemlerin ve karşılaştırılan diğer yöntemlerin sınıflandırma doğrulukları (%)	88
Tablo 4.14 Indian Pines verisi için önerilen yöntemlerin ve karşılaştırılan diğer yöntemlerin sınıflandırma doğrulukları	91

Tablo 4.15	İstanbul müsilağ verisi için önerilen yöntemlerin ve karşılaştırılan diğer yöntemlerin sınıflandırma doğrulukları (%)	96
Tablo 4.16	Bursa müsilağ verisi için önerilen yöntemlerin ve karşılaştırılan diğer yöntemlerin sınıflandırma doğrulukları (%)	100
Tablo 4.17	Bursa veri kümesinden alınan eğitim verileri ile İstanbul veri kümesi üzerinde yapılan deneyler için önerilen yöntemlerin ve karşılaştırılan diğer yöntemlerin sınıflandırma doğrulukları (%)	101
Tablo 4.18	İstanbul veri kümesinden alınan eğitim verileri ile Bursa veri kümesi üzerinde yapılan deneyler için önerilen yöntemlerin ve karşılaştırılan diğer yöntemlerin sınıflandırma doğrulukları (%)	103
Tablo 4.19	Indian Pines ve İstanbul müsilağ veri kümeleri için yöntemlerin yürütme süreleri (saniye cinsinden)	105

ŞEKİLLER

	<u>Sayfa</u>
Şekil 1.1 Aktif ve pasif uzaktan algılama sensörleri.	2
Şekil 1.2 Hiperspektral görüntüler ile RGB görüntüler arasındaki fark	2
Şekil 1.3 Temsili bir hiperspektral veri küpü ve veri küpü içerisinde farklı konumlarda yer alan nesnelere ait spektral imzalar.....	4
Şekil 1.4 Literatürde bulunan gösterim tabanlı yöntemlerden bazıları	12
Şekil 2.1 Eğitim verisine ait notasyonlar için görseller	18
Şekil 2.2 Test pikseli y ve uzamsal bilgiden yararlanmak için kullanılan piksel kümesi Y notasyonları için görseller	18
Şekil 2.3 SRC yönteminin ilgilendiği problem. Bu yöntemde seyreklik kısıtı vardır.	20
Şekil 2.4 CRC yönteminin ilgilendiği problem	22
Şekil 2.5 NSC yönteminde test pikseli için sınıfa özgü eğitim verileri ile ayrı ayrı kestirim elde edilmeye çalışılmaktadır.	22
Şekil 2.6 NSC yönteminin geometrik yorumu	24
Şekil 2.7 CRC, SRC ve NSC yöntemlerinde ilgili optimizasyon problemleri çözüldükten sonra her bir sınıf için geri çatım hatası hesaplanmaktadır. Hangi sınıf için geriçatım hatası daha düşük ise test pikseli o sınıfa atanmaktadır.	26
Şekil 3.1 Tez kapsamında önerilen yöntemlerin kategorizasyonu. Önerilen SSNSC yaklaşımı kullanılarak dört farklı yöntem geliştirilmiştir. Bu yöntemler arasından WBNSC yöntemi uzamsal bilgi olarak test pikseli komşuluğu içerisinde yer alan uzamsal bir pencere içerisindeki piksellerden yararlanırken, SBNSC yöntemi ise süperpiksel içerisinde yer alan piksellerden yararlanmaktadır. Ayrıca, SBNSC yönteminin iki farklı uzantısı: MSBNSC ve SBNSCMV yöntemleri de tez kapsamında önerilmiştir.	31

Şekil 3.2	Önerilen SSNSC yaklaşımının geometrik yorumu ve bu yaklaşımda CCA yönteminin kullanım şekli.	35
Şekil 3.3	Önerilen SSNSC yaklaşımı ile etiket kestirimi	39
Şekil 3.4	Önerilen WBNSC yönteminde uzamsal bilgiden yararlanırken test pikseli y 'nin komşuluğundaki sabit bir pencere içerisinde yer alan piksellerden yararlanılmaktadır.....	41
Şekil 3.5	WBNSC yöntemi ile bir test pikselinin sınıflandırılması	41
Şekil 3.6	Önerilen süperpiksel tabanlı yöntemlerde süperpiksellerin elde edilmesi	44
Şekil 3.7	SBNSC yöntemi ile bir superpikselin sınıflandırılması	44
Şekil 3.8	Önerilen MSBNSC yönteminin çalışma adımları	46
Şekil 3.9	Önerilen SBNSCMV yönteminin adımları	47
Şekil 3.10	SBNSCMV yönteminin ilk iki aşaması sonrasında elde edilen iki farklı senaryo için sınıflandırma haritaları: Bu aşamadan sonra test süperpikseli S_T 'nin nihai etiketi, kendisinin ve kendisine bitişik olan süperpiksellerin kestirilen etiketleri dikkate alınarak çoğunluk oylama ile belirlenmektedir. Son aşama (çoğunluk oylama) sonrasında Senaryo 1'de yer alan test süperpikseli için elde edilen nihai etiket C3 olarak kalmaktayken Senaryo 2'de yer alan test süperpikseli için elde edilen nihai etiket C2 olarak değiştirilmektedir.	48
Şekil 4.1	Indian Pines verisi için yapay renkli görüntü ve yer-gerçekliği görüntüsü (Beyaz renkli bölgeler etiketsiz verileri göstermektedir.)	52
Şekil 4.2	Salinas verisi için yapay renkli görüntü ve yer-gerçekliği görüntüsü (Beyaz renkli bölgeler etiketsiz verileri göstermektedir.)	53
Şekil 4.3	Botswana verisi için yapay renkli görüntü ve yer-gerçekliği görüntüsü.	54
Şekil 4.4	Müsilaj verisi için kullanılan bölgeler	56
Şekil 4.5	PRISMA uydularına ait spektral yanıt fonksiyonu. Görselde siyah çizgiler PRISMA uydusuna ait spektral yanıtları göstermektedir.	57
Şekil 4.6	İstanbul müsilaj verisi için yapay renkli görüntü ve yer-gerçekliği görüntüsü. Yer-gerçekliği görüntüsünde mavi renkli bölgeler denizi beyaz renkli bölgeler müsilajı göstermektedir.	57

Şekil 4.7	Bursa müsilaaj verisi için yapay renkli görüntü ve yer-gerçekliği görüntüsü. Yer-gerçekliği görüntüsünde mavi renkli bölgeler denizi beyaz renkli bölgeler müsilaajı, siyah renkli bölgeler etiketsiz verileri göstermektedir.	58
Şekil 4.8	Sentetik veriler ile yapılan deneylerde kullanılan 3 sınıf için eğitim verileri: Her bir sınıfta 5 tane eğitim verisi bulunmaktadır. Referans olması açısından eğitim verilerinin birbirleri ile olan kanonik korelasyon değerleri de verilmektedir. C1'e ait eğitim verileri ile C2'ye ait eğitim verileri arasındaki en büyük kanonik korelasyon değeri 0.9359, C1'e ait eğitim verileri ile C3'e ait eğitim verileri arasındaki en büyük kanonik korelasyon değeri 0.8961 ve C2'ye ait eğitim verileri ile C3'e ait eğitim verileri arasındaki en büyük kanonik korelasyon değeri 0.9363'tür.	60
Şekil 4.9	Uzamsal bölge içerisinde yer alan gürültülü piksellerin sınıflandırma performansına etkisinin incelenmesi için sentetik veriler ile oluşturulan senaryolar.....	61
Şekil 4.10	Uzamsal bölge içerisinde farklı sınıflara ait piksellerin bulunduğu durumlarda SSNSC yaklaşımının davranışının analizi için sentetik veriler ile oluşturulan senaryolar	63
Şekil 4.11	Uzamsal bölge içerisinde farklı sınıflara ait piksellerin bulunduğu durumlarda SSNSC yaklaşımının davranışının analizi için sentetik veriler ile oluşturulan senaryolar	64
Şekil 4.12	Uzamsal pencere boyutunun önerilen yöntemimiz üzerindeki etkisinin analizi. Sırasıyla (a) Salinas (b) Indian Pines ve (c) Botsvana veri kümeleri için yer-gerçekliği görüntüleri ve farklı uzamsal pencere boyutları 1, 3, 5, 7, 9 için sınıflandırma haritaları.....	67
Şekil 4.13	Indian Pines veri sahnesi içerisinde örnek bir bölge üzerinden uzamsal pencere boyutunun önerilen yöntemimiz üzerindeki etkisinin analizi. ..	68

Şekil 4.14 Salinas verisi için WBNSC yöntemi ve karşılaştırılan diğer yöntemler ile elde edilen sınıflandırma haritaları. Sınıf başına 40 örnek eğitim verisi olarak kullanılmış, geriye kalan örnekler test verisi olarak kullanılmıştır.....	71
Şekil 4.15 Indian Pines verisi için WBNSC yöntemi ve karşılaştırılan diğer yöntemler ile elde edilen sınıflandırma haritaları. Sınıf başına 40 örnek eğitim verisi olarak kullanılmış, geriye kalan örnekler test verisi olarak kullanılmıştır.....	74
Şekil 4.16 Botswana verisi için WBNSC yöntemi ve karşılaştırılan diğer yöntemler ile elde edilen sınıflandırma haritaları. Sınıf başına 40 örnek eğitim verisi olarak kullanılmış, geriye kalan örnekler test verisi olarak kullanılmıştır.....	76
Şekil 4.17 Yöntemlerin (a) Salinas, (b) Indian Pines ve (c) Botswana veri kümeleri üzerinde değişen sınıf başına eğitim örneği sayıları için sınıflandırma performansları.....	78
Şekil 4.18 Salinas verisi üzerinde WBNSC ve SBNSC yöntemlerine ait sınıflandırma haritalarının karşılaştırması (a) WBNSC yöntemi ile elde edilen sınıflandırma haritası (b) SBNSC yöntemi ile elde edilen sınıflandırma haritası süperpikseller ile birlikte verilmiştir. (c) SBNSC yöntemi ile elde edilen sınıflandırma haritası.	83
Şekil 4.19 Salinas verisi üzerinde SBNSC ve SBNSCMV yöntemlerine ait sınıflandırma haritalarının karşılaştırması. (a) SBNSC yöntemi ile elde edilen sınıflandırma haritası, (b) SBNSCMV yöntemi çoğunluk oylama fazı yapılmadan önce elde edilen sınıflandırma haritası, (c) SBNSCMV yöntemi için çoğunluk oylama fazı uygulandıktan sonra elde edilen sınıflandırma haritası.	84

Şekil 4.20 Salinas veri kümesi üzerinde MSBNSC yöntemi için ara aşamalara ait sınıflandırma haritaları ve nihai sınıflandırma haritası. (a) Ölçek 1 ile elde edilen sınıflandırma haritası (Süperpiksel sayısı az/süperpiksel boyutları büyük), (b) Ölçek 5 ile elde edilen sınıflandırma haritası (Süperpiksel sayısı çok/süperpiksel boyutları küçük), (c) MSBNSC yöntemi için nihai sınıflandırma haritası.	85
Şekil 4.21 Salinas verisi için önerilen yöntemler ve karşılaştırılan diğer yöntemler ile elde edilen sınıflandırma haritaları. Sınıf başına 20 örnek eğitim verisi olarak kullanılmış, geriye kalan örnekler test verisi olarak kullanılmıştır.	87
Şekil 4.22 Indian Pines verisi için önerilen yöntemler ve karşılaştırılan diğer yöntemler ile elde edilen sınıflandırma haritaları. Sınıf başına 20 örnek eğitim verisi olarak kullanılmış, geriye kalan örnekler test verisi olarak kullanılmıştır.	89
Şekil 4.23 Yöntemlerin (a) Salinas, (b) Indian Pines veri kümeleri üzerinde değişen sınıf başına eğitim örneği sayıları için sınıflandırma performansları	92
Şekil 4.24 İstanbul müsilaaj verisi için önerilen yöntemler ve karşılaştırılan diğer yöntemler ile elde edilen sınıflandırma haritaları. Sınıf başına 20 örnek eğitim verisi olarak kullanılmış, geriye kalan örnekler test verisi olarak kullanılmıştır.	97
Şekil 4.25 Bursa müsilaaj verisi için önerilen yöntemler ve karşılaştırılan diğer yöntemler ile elde edilen sınıflandırma haritaları. Sınıf başına 20 örnek eğitim verisi olarak kullanılmış, geriye kalan örnekler test verisi olarak kullanılmıştır.	99
Şekil 4.26 Bursa veri kümesinden alınan eğitim verileri ile İstanbul veri kümesi üzerinde yapılan deneyler için önerilen yöntemler ve karşılaştırılan diğer yöntemler ile elde edilen sınıflandırma haritaları. Sınıf başına 20 örnek eğitim verisi olarak kullanılmış, geriye kalan örnekler test verisi olarak kullanılmıştır.	102

Şekil 4.27 İstanbul veri kümesinden alınan eğitim verileri ile Bursa veri kümesi üzerinde yapılan deneyler için önerilen yöntemler ve karşılaştırılan diğer yöntemler ile elde edilen sınıflandırma haritaları. Sınıf başına 20 örnek eğitim verisi olarak kullanılmış, geriye kalan örnekler test verisi olarak kullanılmıştır. 104



SİMGELER VE KISALTMALAR

Simgeler

$Col(.)$	: Matrisin kolon uzayı
$\mathcal{L}$	: Lagranj (Lagrangian) fonksiyonu
$\ \cdot\ _F$	: Vektörün Frobenius normu
$\ \cdot\ _0$	: Vektörün l_0 (sözde) normu
$\ \cdot\ _1$	: Vektörün l_1 normu
$\ \cdot\ _2$	: Vektörün l_2 normu
$(\cdot)^{-T}$	: Matrisin devriği
$(\cdot)^{-1}$	: Matrisin tersi
C	: Veri kümesi içerisinde yer alan etiketli sınıf sayısı
n_i	: i . sınıf için kullanılan eğitim örneği sayısı
N	: Toplam eğitim örneği sayısı
$Col(\mathbf{X}_i)$	: $\mathbf{X}_i$ 'nin kolon uzayı
$Col(\mathbf{Y})$	: $\mathbf{Y}$ 'nin kolon uzayı
r_i	: y ile $Col(\mathbf{X}_i)$ arasındaki minimum Öklit uzaklığı
T	: Pencere tabanlı yöntemlerde kullanılan pencere boyutu parametresi
x_{ij}	: i . sınıfa ait j . eğitim verisi
$\mathbf{X}_i$	: i . sınıfa ait eğitim verisinin tümü
y	: Test verisi
$\mathbf{Y}$	: Sınıflandırma sırasında uzamsal bilgiden yararlanmak için kullanılan pikseller kümesi
v_{x_i}, v_{y_i}	: Sırasıyla $Col(\mathbf{X}_i)$ ve $Col(\mathbf{Y})$ içerisinde yer alan maksimum korelasyonlu vektör çifti
ρ_i	: v_{x_i} ve v_{y_i} arasındaki korelasyon

Kısaltmalar

AA	: A verage A ccuracy (Ortalama Doğruluk)
BP	: B asis P ursuit (Baz Takip)
CCA	: C anonical C orrelation A nalysis (Kanonik Korelasyon Analizi)
CRC	: C ollaborative R epresentation-Based C lassifier (İşbirlikçi Gösterim Tabanlı Sınıflandırıcı)
CCJSR	: C orrelation C oefficient with J oint S pase R epresentation C lassifier (Korelasyon Katsayısı ile Ortak Seyrek Gösterim Tabanlı Sınıflandırıcı)
FNR	: F alse N egative R ate (Yanlış Negatif Oranı)
FPR	: F alse P ositive R ate (Yanlış Pozitif Oranı)
JNSC	: J oint N earest S ubspace C lassifier (Ortak En Yakın Altuzay Sınıflandırıcısı)
JSRC	: J oint S pase R epresentation-Based C lassifier (Ortak Seyrek Gösterim Tabanlı Sınıflandırıcı)
LSRC	: L ocality- C onstrained S pase R epresentation C lassification (Yerellik Kısıtlı Seyrek Gösterim Tabanlı Sınıflandırıcı)
MSBNSC	: M ulti- S cale S uperpixel B ased N earest S ubspace C lassifier (Çok-Ölçekli Süperpiksel Tabanlı En Yakın Altuzay Sınıflandırıcısı)
NIR	: N ear I nfrared (Yakın Kızılötesi)
NP-Hard	: N on- D eterministic P olynomial T ime- H ard (Deterministik Olmayan Zaman-Zor Polinom)
NRS	: N earest R egularized S ubspace C lassifier (Düzenlenmiş En Yakın Altuzay Sınıflandırıcısı)

NSC	: N earest S ubspace C lassifier (En Yakın Altuzay Sınıflandırıcısı)
OA	: O verall A ccuracy (Genel Doğruluk)
OMP	: O rthogonal M atching P ursuit (Dik Eşleme Takip)
PCA	: P rincipal C omponent A nalysis (Temel Bileşen Analizi)
RJNSC	: R obust J oint N earest S ubspace C lassifier (Dayanıklılı Ortak En Yakın Altuzay Sınıflandırıcısı)
RBF	: R adial B asis F unction (Radyal Temelli Fonksiyon)
RPNet	: R andom P atch N etwork (Rastgele Yama Ağları)
SaCRT	: S tructure- a ware C ollaborative R epresentation with T ikhonov R egularization (Tikhonov Düzenleyici ile Yapı-Duyarlı İşbirlikçi Gösterim Tabanlı Sınıflandırıcı)
SBNSC	: S uperpixel B ased N earest S ubspace C lassifier (Süperpiksel Tabanlı En Yakın Altuzay Sınıflandırıcısı)
SBNSCMV	: S uperpixel B ased N earest S ubspace C lassifier with M ajority V oting (Çoğunluk Oylama ile Süperpiksel Tabanlı En Yakın Altuzay Sınıflandırıcısı)
SKCR	: S tructural- K ernel C ollaborative R epresentation C lassifier (Yapısal Çekirdek İşbirlikçi Gösterim Tabanlı Sınıflandırıcı)
SP	: S ubspace P ursuit (Altuzay Takip)
SRC	: S parse R epresentation- B ased C lassifier (Seyrek Gösterim Tabanlı Sınıflandırıcı)
SSNSC	: S pectral S patial N earest S ubspace C lassifier (Spektral-Uzamsal En Yakın Altuzay Sınıflandırıcısı)

- SVM-MV** : Support Vector Machines with Majority Voting
(Çoğunluk Oylama ile Destek Vektör Makineleri)
- TNR** : True Negative Rate
(Gerçek Negatif Oranı)
- TPR** : True Positive Rate
(Gerçek Pozitif Oranı)
- UV** : Ultraviolet
(Ultraviyole)
- WBNSC** : Window Based Nearest Subspace Classifier
(Pencere Tabanlı En Yakın Altuzay Sınıflandırıcısı)

1. GİRİŞ

Uzaktan algılama, “bir nesneyle fiziksel temasa girmeden onun hakkında bilgi çıkarmakla ilgili çalışma alanı” olarak tanımlanmıştır [1]. Bu bağlamda, uzaktan algılama; uçak, uydu vb. gibi yer, hava ve uzay platformlarına yerleştirilen farklı uzaktan algılama sensör teknolojileri sayesinde maddelerden yansıyan elektromanyetik enerjinin kaydedilmesi, elde edilen verilerin işlenmesi ve yorumlanması ile ilgilidir [2].

Uzaktan algılama yoluyla elektromanyetik enerjinin toplanması dört bileşenden oluşmaktadır [3]. Bu bileşenler; enerji kaynağı, atmosfer ile etkileşim, dünya yüzeyi ile olan etkileşim ve sensördür. Sistemin bileşenleri arasındaki bağlantı, radyasyon yoluyla aktarılan elektromanyetik enerjidir.


Enerji kaynağı: Elektromanyetik radyasyon kaynağı; güneş gibi doğal bir kaynak olabileceği gibi mikrodalga radar gibi insan yapımı olabilir. Pasif sistemler, güneşten yayılan doğal radyasyonu veya mutlak sıfırın üzerindeki sıcaklıklara sahip tüm nesneler tarafından yayılan termal radyasyonu algılamak, aktif sistemler radyasyon yayar ve geri dönen sinyali analiz eder. Bu iki tür sensör ile yapılan uzaktan algılama sistemlerinin çalışma mekanizmalarını anlatan görseller Şekil 1.1’de yer almaktadır.

Atmosfer ile etkileşim: Atmosferde yayılan elektromanyetik radyasyonun özellikleri, soğurulma ve saçılma gibi çeşitli işlemlerden dolayı bozulur. Bu bozulma istenmeyen bir durumdur ve dünyanın yüzeyinin incelenmesi durumunda düzeltme gerektirmektedir.

Dünya yüzeyi ile olan etkileşim: Dünya yüzeyinden yansıyan ya da dünya yüzeyi tarafından soğurulan radyasyonun miktarı ve spektral dağılımı, ilgili “hedef” malzemelerin özelliklerine bağlıdır. Madde ve elektromanyetik enerji arasındaki etkileşim, (a) maddenin fiziksel özellikleri ve (b) uzaktan algılanan elektromanyetik enerjinin dalga boyu tarafından belirlenir.

Sensör: Dünya yüzeyi ve atmosfer ile etkileşime giren elektromanyetik radyasyon, sensörler tarafından ilgili spektral bantlar için elektriksel sinyallere çevrilip kaydedilir. Bu elektriksel sinyaller dijital verilere dönüştürülür ve işlenebilecek bir veri yapısı haline getirilir. Sensör


tarafından alınan radyasyon, bir sahnenin farklı konumlarında, çeşitli dalga boylarında ve bazen farklı zamanlarda ölçülebilir. Bu, farklı açılardan analiz yapılabilecek veri kümelerinin elde edilmesine olanak sağlar. Tez kapsamında uzaktan algılama görüntüleme sistemlerinden hiperspektral görüntü sistemleri ile elde edilen hiperspektral görüntüler ile ilgilenilmektedir.



Şekil 1.1 Aktif ve pasif uzaktan algılama sensörleri. ([4]'ten esinlenerek çizilmiştir.)

1.1. Hiperspektral Görüntü

Geleneksel kameralar; görüntüleri kırmızı, yeşil ve mavi (RGB) bantlarında olmak üzere üç bantta kaydeder. Hiperspektral kameralar (sensör) ise görüntüleri yalnızca RGB bantlarında değil, görünür spektrumun ötesine uzanan yüzlerce bantta kaydeder. Hiperspektral görüntüler ile RGB görüntüler arasındaki fark Şekil 1.2'de görselleştirilmiştir.



Şekil 1.2 Hiperspektral görüntüler ile RGB görüntüler arasındaki fark. ([5, 6]'dan esinlenerek çizilmiştir.)

Hiperspektral sensörler, elektromanyetik spektrumun optik bölgelerine ait Tablo 1.1'de bilgileri özetlenen görünür ve kızılötesi bölgelerinden nispeten dar, bitişik yüzlerce spektral

banttan aynı anda dijital görüntüler toplar. Her bir spektral bant elektromanyetik spektrumun farklı bir bölgesini ifade etmektedir. Bu bantların her biri için bir görüntü oluşturulur ve her bir görüntü gri tonlama seviyeleri ile kodlanır. Bu görüntüler farklı dalgalı boyundaki bantlar için birleştirilerek işleme ve analiz için bir veri küpü oluşturulur. Bu veri küpü hiperküp olarak adlandırılan, iki boyutunda uzamsal bilgi ve üçüncü boyutunda spektral bilgi içeren üç boyutlu bir matristir. Bir hiperspektral görüntü içerisindeki her bir piksel de, uzunluğu spektral bantların sayısına eşit olan bir vektör olarak düşünülebilir. Hiperspektral görüntüler genellikle 0.4 ve 2.5 μm arasındaki bir dalgalı boyu bölgesinde dar bir bant genişliği (5–10 nm) ile 100’den fazla bitişik spektral banttan alınan görüntülerden oluşur [7, 8]. Başka bir deyişle, hiperspektral görüntüleme; dijital görüntülemeyi, spektroskopi ile birleştirir ve görüntüdeki her bir piksel için uzamsal ve spektral bilgi sağlar [9]. Hiperspektral görüntülerde çözünürlük kavramları önemlidir. Bir görüntünün çözünürlüğü, görüntüler tarafından sağlanan ayrıntıyı ifade eder. Hiperspektral görüntü sınıflandırmada analiz ve yorum yapmak için önemli bilgiler sağlayan iki tür çözünürlükten söz edebiliriz. Bunlar, spektral ve uzamsal çözünürlüktür.


- **Uzamsal Çözünürlük**, bir görüntüdeki bir pikselin görüntü alınan bölgede gerçekte ne kadar büyüklükte bir alanı temsil ettiğini ifade etmektedir. Bir pikselin kare bir alanı temsil ettiği düşünülürse, uzamsal çözünürlük bu karenin bir kenarının uzunluğunu temsil eden tek bir değer olarak sunulur. Örneğin, 20m’lik bir uzamsal çözünürlük, bir pikselin yeryüzünde $20 \times 20 \text{ m}^2$ ’lik bir alanı temsil ettiği anlamına gelir [10].
- **Spektral Çözünürlük**, sensörün elektromanyetik spektrumun belirli dalgalı boylarını ölçme hassasiyetini ifade eder. Spektrumun ilgili bölgesi ne kadar dar ve çok parçaya ayrılırsa spektral çözünürlük o kadar yüksek olur. Başka bir deyişle, spektral çözünürlük ne kadar yüksek olursa, belirli bir spektral aralık için bant sayısı o kadar fazla olur.

Her bir malzeme için yansıyan, yutulan veya iletilen ışınım miktarları dalgalı boyuna bağlı olarak değişir. Her malzeme, kendine özel moleküler geometrisi sayesinde yansıtıcı spektral bölgede benzersiz bir yansıtma davranışına sahiptir. Bu yansıma değerleri grafiksel bir

Tablo 1.1 Elektromanyetik spektrumun optik bölgesi için dalgaboyu bilgileri

Atmosferik Pencere			Dalgaboyu
Ultraviyole			0.001~0.4 μm
Görünür		Mavi	0.4~0.5 μm
		Yeşil	0.5~0.6 μm
		Kırmızı	0.6~0.7 μm
Kızılötesi	Yansıyan Kızılötesi	Yakın Kızılötesi	0.7~1.3 μm
		Kısa Dalga Kızılötesi	1.3~3.0 μm
	Termal Kızılötesi	Orta Dalga Kızılötesi	3~8 μm
		Termal Dalga Kızılötesi	8~14 μm
		Uzak Dalga Kızılötesi	14 μm ~1 mm

ortamda karakteristik bir örüntü ile temsil edilir. Bu örüntüye spektral imza denmektedir. Bu imza, nesnelerin fiziksel veya kimyasal özelliklerini tahmin etmek için bir ipucu olarak kullanılabilir. Sahne içerisinde yer alan her bir piksele ait spektral bilgi, ilgili materyallerin spektral imzalarıyla ilişkilendirilir ve spektral imzalardaki benzersizlik, sahne içerisinde yer alan pikselleri sınıflandırmak için ayırt edici güç sağlar. Temsili bir hiperküp ve hiperküp içerisinde farklı konumlarda yer alan piksellerde yer alan üç farklı materyal ve bu materyallerin spektral imzaları Şekil 1.3'te verilmiştir.



Şekil 1.3 Temsili bir hyperspektral veri küpü ve veri küpü içerisinde farklı konumlarda yer alan nesnelere ait spektral imzalar. ([4]'ten esinlenerek çizilmiştir.)

Hiperspektral sensörler tarafından toplanan ayrıntılı spektral bilgiler, farklı arazi örtüsü sınıfları arasında ayırım yapma kabiliyetini artırması sayesinde dünya yüzeyini analiz etmek amacıyla askeri [11], mineral bilimi [12], okyanus bilimi [13] ve tarım [14] gibi bir çok uzaktan algılama alanında yaygın olarak kullanılmaktadır [15, 16]. Hiperspektral görüntü işleme üzerine yapılan çalışmalar bu uygulama alanlarındaki ihtiyaca göre farklı araştırma alanlarına dallanmıştır. Bu araştırma alanlarından bazıları kısaca şu şekilde özetlenebilir:

- **Spektral ayrıştırma (Spectral unmixing):** Düşük uzamsal çözünürlük nedeniyle bir piksel, uzamsal sınırları içerisinde birden fazla materyali bünyesinde barındırabilir. Katışım pikselleri (mixed pixels) olarak adlandırılan bu piksellere ait spektral bilgi, materyallerin imzalarının karışımı formunda olmaktadır. Spektral ayrıştırma, ölçülen katışım pikselinin bileşenlerine ayrıştırılması ve her bir bileşenin piksel içerisindeki katışım oranlarının bulunması ile ilgilenen bir araştırma alanıdır [17–19].
- **Hedef tespiti (Target detection):** Etiketli hedef ve arkaplan verileri yardımıyla görüntü içerisindeki hedef piksellerinin tespiti işlemidir. Uydu kullanılarak elde edilen görüntülerden düşman aracının tespiti, gömülü cisim tespiti bu araştırma alanına ait uygulamalar arasında yer alır [20–22].
- **Değişiklik tespiti (Change detection):** Aynı coğrafi alan üzerinden farklı zamanlarda görüntüler toplanması ve bu iki görüntü arasındaki farklılıkların tespit edilmesi ile ilgilenen bir araştırma alanıdır [23].
- **Sınıflandırma (Classification):** Bir coğrafi bölgeden alınan bir hiperspektral görüntü çeşitli arazi örtülerinden oluşur. Her bir arazi örtüsü görüntüde farklı bir sınıfa karşılık gelmektedir. Görüntüdeki her bir pikselin bu sınıflardan hangisine ait olduğunun bulunması gerekmektedir. Sınıflandırma, bu etiketin çeşitli algoritmalar ile doğru bir şekilde belirlenmesini amaçlamaktadır [15, 24, 25].

Bu araştırma alanları arasında en popüler olanlardan biri hiperspektral görüntü sınıflandırmasıdır. Tez kapsamında da ağırlıklı olarak hiperspektral görüntü sınıflandırma

üzerinde durulmuştur, ayrıca denizler içerisinde müsilaj tespiti ile de ilgilenilmiştir. Müsilaj tespiti problemi bu tez kapsamında veri kümesi içerisinde sadece deniz ve müsilaj sınıflarının bulunduğu ikili sınıflandırma (binary classification) problemi olarak ele alınmıştır.

1.2. Hiperspektral Görüntü Sınıflandırma

Hiperspektral görüntü sınıflandırma, hiperspektral bir görüntüde yer alan her bir piksele bir etiket atamayı amaçlar. Sınıflandırma adımı sonrası görüntüde yer alan her bir piksel için kestirilmiş etiketlerin bulunduğu harita, hiperspektral görüntü işleme terminolojisinde sınıflandırma haritası (classification map) olarak ifade edilmektedir. Hiperspektral görüntüler içerdiği zengin spektral bilgi sayesinde sınıflar arasında yüksek ayırt edicilik sağlamasına rağmen hiperspektral görüntü sınıflandırmada karşılaşılan bazı zorluklar da vardır. Araştırmacıların sınıflandırma sırasında karşılaştıkları zorluklardan bazıları aşağıda özetlenmiştir.

- **Yüksek boyutluluk:** Hiperspektral görüntüleme sistemleri ile yüzlerce dalgaboyu aralığından alınan ölçümler, materyallere ait parmak izleri çıkartılarak piksel bazında sınıflandırma yapma sürecinde büyük kolaylık sağlıyor olsa da; yüksek boyutluluk beraberinde problemlere de neden olmaktadır. Yüksek boyutluluk, boyutsallık lanetine (curse of dimensionality) ve dolayısı ile yüksek hesaplama maliyeti ve hesaplama süresine neden olmaktadır. [26, 27]. Bu zorlukla başa çıkmak için bazı yöntemler sınıflandırmaya işleminden önce bant seçme [28], boyut indirgeme [29, 30], öznitelik çıkarma gibi işlemlerden yararlanarak veri boyutunu düşürmektedirler. Bu tarz yaklaşımlar, bazı bilgilerin kaybolması ihtimalini göze alarak yüksek boyuttan kaçınmayı amaçlamaktadırlar.
- **Sınırlı eğitim verisi:** Yüksek boyutlu verilerle çalışılırken sınıflandırmada yüksek başarımlar elde edilebilmesi için eğitim verisi sayısının da yeterince fazla olması gerekmektedir. Fakat hiperspektral görüntülerde veri toplama ve etiketleme işleminin zaman alıcı ve maliyetli olması nedeniyle eğitim verisi sayısı, hiperspektral görüntülerdeki bant sayısı ile kıyaslandığında genellikle sınırlıdır [31]. Bu nedenle, hiperspektral

görüntü (HSG) işleme alanında geliştirilen sınıflandırma yaklaşımlarının, sınırlı sayıda eğitim örneği mevcut olduğunda yüksek boyutlu veriler ile iyi sonuçlar vermesi gerekmektedir. Bazı yöntemler ise sınırlı eğitim örneği zorluğu ile başa çıkmak için elde bulunan eğitim verilerine gürültü ekleme ve/veya eğitim verilerinin farklı oranlarda doğrusal kombinasyonlarını alma yoluyla veri artırımı (data augmentation) işlemi yaparak yapay eğitim verileri oluşturmaktadır [32–34].

- **Katışım pikselleri:** Düşük uzamsal çözünürlük nedeniyle bir pikselin kapsadığı uzamsal sınırlar birden fazla materyal barındırabilmektedir. Bu yüzden, piksele ait spektral bilgi, pikselin içerdiği materyallerin yansıma değerlerinin belirli bir oranda karışımı halinde olmaktadır. Bu, ilgili pikselin spektral bilgisinin ait olduğu materyalin spektral imzasından farklılaşmasına neden olmaktadır. Bu da bir pikselinin etiketinin belirlenmesini zorlaştıran etmenlerden bir diğeridir [10, 35].
- **Sınıf içi örnekler içerisindeki spektral değişkenlik ve sınıflar arası örnekler arasındaki spektral benzerlikler:** Materyallerin spektral imzaları benzersiz gibi düşünülse de bazı malzemelerin spektral imzaları birbirine benzemektedir. Ayrıca atmosferik koşullar, piksellerin karışım halinde olması, alınan görüntülerde piksellerin gölge/güneş altında kalması vb. durumlarda sınıf içi örnekler arasında spektral değişkenlikler olabilmektedir [8, 36].
- **Yanlış etiketlenmiş eğitim verileri:** Eğitim örnekleri genellikle elle etiketlenmektedir. Bu süreçte yanlış etiketleme yapılabilmektedir.
- **Gürültülü pikseller:** Hiperspektral bir görüntü, düşük sinyal gürültü oranı (signal to noise ratio, SNR) ve su absorpsiyonu bantları gibi bazı kötü bantlar içerebilmektedir. Ayrıca sensör saturasyonu nedeniyle beyaz noktalar gibi kötü pikseller içerebilir. Bu kötü bantlar ve kötü pikseller sınıflandırma performansını etkiler. Sınıflandırmadan önce mümkünse bu tarz sorunların giderilmesi gerekmektedir [37].

Yukarıda bahsedilen zorlukların çoğu hiperspektral görüntü (HSG) işleme alanına özeldir ve HSG işleme ile RGB görüntü işlemenin farklılaştığı noktalardır. Bu yüzden, RGB

görüntü işleme için tasarlanmış yaygın olarak kullanılan sınıflandırma yöntemleri, hiperspektral görüntüler için her zaman elverişli değildir. Bu nedenler literatürde hiperspektral görüntü işlemeye özel yöntemlerin geliştirilmesine ön ayak olmuştur. Bu yöntemlerin geliştirilmesi süresince görüntü işlemenin yanı sıra bilgisayarlı görü, makine öğrenmesi, örüntü tanıma alanlarından da yararlanılmıştır.

Farklı kriterlere göre HSG sınıflandırma yöntemleri kategorize edilebilir. Örneğin, sınıflandırma sırasında eğitim verisinin kullanılıp kullanılmamasına bağlı olarak, sınıflandırma yaklaşımları, denetimli (supervised) ve denetimsiz (unsupervised) sınıflandırıcılar olmak üzere iki kategoriye ayrılabilir. Denetimli sınıflandırma yaklaşımları, eğitim verisi olarak isimlendirilen etiketli bir veri kümesi yardımıyla sahne içerisinde bulunan test verisi olarak isimlendirilen verilerin etiketlerini kestirme işlemi yapan yaklaşımlardır [8, 38]. Diğer yandan, denetimsiz sınıflandırma yaklaşımları, kümeleme (clustering) olarak da bilinir, etiketli örneklerden yararlanmaz [39–41]. Literatürde denetimsiz sınıflandırma yaklaşımları üzerine çok sayıda çalışma bulunmaktadır. Bu yöntemler arasından K-Ortalamalar (K-means) [42], Fuzzy C-Ortalamalar (Fuzzy C-means) [43] ve Yinelemeli Kendi Kendini Düzenleyen Veri Analizi Tekniği (Iterative Self-Organizing Data Analysis Technique, ISODATA) [44] yöntemleri en popüler olanlar arasındadır. Bu tarz yaklaşımlar, ilklendirme konfigürasyonlarına oldukça duyarlıdır. Bu nedenle, bu yaklaşımlar ile elde edilen sonuçlar optimal olmayan çözümlere hapsolabilmektedir [45]. Denetimli yaklaşımlar, eğitim örnekleri tarafından sağlanan sınıfa özel bilgileri dikkate alması sayesinde, denetimsiz yaklaşımlara kıyasla daha iyi sonuçlar vermektedir [8]. Denetimsiz ve denetimli yaklaşımlara ek olarak, literatürde önerilen yarı-denetimli yaklaşımlar da vardır [46, 47]. Bu yöntemler, hem etiketli eğitim örneklerini hem de etiketsiz örnekleri kullanarak sınıflandırma yapmaktadır. Tez kapsamında, denetimli sınıflandırma yaklaşımlarına odaklanılmıştır.

Denetimli sınıflandırma yöntemlerinden destek vektör makineleri (support vector machines, SVM) [48, 49] yöntemi sınırlı sayıda eğitim örneği ile yüksek boyutlu veriler üzerinde başarılı sonuçlar elde edebilmesi nedeniyle hiperspektral görüntü sınıflandırma alanında yaygın olarak kullanılmaktadır. Yapay sinir ağları (artificial neural networks, ANNs)

ile örüntü tanıma alanında karmaşık sınıflandırma senaryolarında başarılı sonuçların elde edilmesi [50] hiperspektral görüntü sınıflandırma alanında çalışan araştırmacıların da dikkatini çekmiş ve bu alanda da bir çok çalışma yapılmıştır [51, 52]. k-en yakın komşu (k-Nearest Neighbour, k-NN) [53, 54] ve varyantları [55], karar ağaçları (decision trees), rastgele orman (random forest, RF) [56, 57] gibi yöntemler de literatürde hiperspektral görüntü sınıflandırma alanında kullanılan diğer yöntemlerdendir.

Son yıllarda yüz tanıma [58], doğal dil işleme [59], rakam sınıflandırma [60], karakter sınıflandırma [61] gibi geniş bir spektrumda derin öğrenme yöntemleri yoğun ilgi görmektedir. Hiperspektral görüntü işleme alanında da literatürde çok sayıda derin öğrenme çalışması bulunmaktadır. Fakat, hiperspektral görüntülerde hem uzamsal hem spektral bilginin bir arada bulunması, buna karşılık etiketli eğitim verilerinin nispeten az kalması bu alanda derin öğrenme yöntemleri için bir darboğaz oluşturmaktadır [62–64]. Bu aşamada, çok sayıda katmanı ve parametresi olan ağır modellerin eğitilmesi iyice zorlaşmakta, tasarımları maliyetli ve karmaşık olmaktadır. Dahası, bu tür modeller çok sayıda etiketli eğitim verisi beklemektedir ki, hiperspektral görüntülerde etiketli veri sayısı sınırlıdır. Etiketli veri sayısı sınırlı olması derin öğrenme yöntemlerinde ezberleme (overfitting) adı verilen ciddi bir soruna yol açabilmektedir ve derin öğrenme yöntemlerinin performanslarını olumsuz yönde etkilemektedir. Ayrıca, derin öğrenme yöntemlerinde ayarlanması gereken parametre sayısı fazladır ve bu parametreleri ayarlaması zordur. Bu bağlamda uygun bir derin ağı nasıl tasarlanacağı, parametrelerin nasıl ayarlanması gerektiği makine öğrenmesi topluluğunda hala açık bir alandır [8].

Bahsedilen yöntemlere alternatif olarak literatürde önerilen bir diğer yaklaşım da gösterim tabanlı sınıflandırma yöntemleridir (representation-based classification methods). Bu yaklaşımlar, test örneklerinin, eğitim örneklerinin ağırlıklı lineer (doğrusal) kombinasyonları ile yaklaşık olarak ifade edilebileceği varsayımına dayanmaktadır. Bu yöntemler arasında, işbirlikçi gösterim tabanlı sınıflandırıcı (collaborative representation based classifier, CRC) [65], seyrek gösterim tabanlı sınıflandırıcı (sparse representation based classifier, SRC) [66], en yakın altuzay sınıflandırıcısı (nearest subspace classifier, NSC) [67, 68] gibi yöntemler bulunmaktadır. Önerdiğimiz sınıflandırma yaklaşımı da gösterim tabanlı bir

yöntemdir. Bu yöntemleri tercih etmemizin nedeni, bu tarz yöntemlerin, derin öğrenme yöntemlerinin aksine büyük eğitim verilerine ihtiyaç duymamasıdır. Birçoğunun kapalı form çözümü (closed form solution) vardır, uygulaması kolaydır. Bu yüzden eğitim süresi de söz konusu değildir. Bu tarz yöntemlerde ayarlanması gereken parametre sayısı genelde derin öğrenme yöntemlerinde olduğu kadar fazla değildir, ayarlanması gereken hiç parametre yoktur ya da çok az sayıdadır. Gösterim tabanlı yaklaşımlarda temel varsayım, test örneğinin eğitim örneklerinin ağırlıklı lineer kombinasyonları ile yaklaşık olarak ifade edilebileceğidir. Bu sayede, gösterim tabanlı yöntemler piksellerin karışım halinde olduğu varsayımı ile sınıflandırma yapmaktadır ve doğaları gereği katışım pikselleri zorluğu ile de doğrudan ilgilenmektedirler.

HSG sınıflandırma yöntemleri uzamsal bilgiyi dikkate alıp almamasına göre spektral sınıflandırıcılar ve spektral-uzamsal sınıflandırıcılar olarak da kategorize edilebilir. Bu kısma kadar bahsettiğimiz yöntemler sadece spektral bilgiyi kullanan yöntemlerdir. Bir hiperspektral görüntüde homojen yapılar genellikle bir piksel boyutundan daha büyüktür, bu nedenle komşu pikseller genelde aynı sınıfa aittir. Ayrıca, uzaktan algılama sensörleri ile veri toplanırken bitişik piksellerden önemli miktarda enerji alınır, bu nedenle komşu pikseller yüksek oranda birbiriyle ilişkilidir. Bu sayede bitişik piksellerden gelen uzamsal ve bağlamsal (contextual) bilgiler sahneye dair değerli bilgiler sağlayabilmektedir. Sadece spektral bilgi dikkate alındığında ortaya çıkan etiketleme belirsizliği uzamsal bilgi kullanılarak azaltılabilir ve bu sayede sınıflandırma haritasında oluşan tuz ve biber görünümünün üstesinden gelinebilmektedir ve gürültülü piksellerle başa çıkılabilmektedir [31, 66]. Uzamsal bilginin sağlayabileceği bu avantajlar, spektral-uzamsal tabanlı sınıflandırıcıların geliştirilmesini tetiklemiştir. Bu iki kaynaktan birlikte yararlanmanın, karmaşık sahnelerde sınıflandırıcıların ayırt etme gücünü önemli ölçüde iyileştirebildiği birçok araştırmada ispatlanmıştır [69–72].


Bu avantajları sayesinde literatürde daha önce üzerinde durduğumuz spektral tabanlı yöntemlerin uzamsal bilgiyi kullanan uzantıları önerilmiştir. Örneğin, literatürde K-NN yönteminin, SVM yönteminin, derin öğrenme yöntemlerinin uzamsal bilgiyi kullanan uzantıları önerilmiştir [73–77]. Uzamsal bilginin kullanımı gösterim tabanlı yöntemlerde de

yaygındır. Uzamsal bilgiden yararlanmak için önerilen ilk gösterim tabanlı yöntemler ortak en yakın altuzay sınıflandırıcısı (joint nearest subspace classifier, JNSC) [78] ve ortak seyrek gösterim tabanlı sınıflandırıcı (joint sparse representation based classifier, JSRC) [66] gibi pencere tabanlı yöntemler olmuştur. Bu yöntemler, sınıflandırma sırasında uzamsal bilgiden yararlanmak için test pikseli etrafındaki sabit bir kare pencere içerisinde yer alan örneklerden yararlanmaktadır. Test pikselinin komşuluğu farklı sınıflardan pikseller içerebileceğinden, pencerenin kullanılması özellikle sınıf sınırlarında yanlış sınıflandırmaya neden olabilmektedir. Ayrıca bu tarz pencere tabanlı yöntemlerde uzamsal bilgi kullanılmasına rağmen piksel bazında sınıflandırma yapılmaktadır. Yalnızca tek bir test pikselinin etiketini tahmin etmek için uzamsal pencere içerisinde yer alan çok sayıda yüksek boyutlu pikselin kullanılması bu tarz yöntemleri zaman alıcı hale getirmektedir. Bu problemlerin üstesinden gelmek ve hiperspektral görüntü sınıflandırmada uzamsal bilgiyi daha etkili kullanabilmek için literatürde süperpiksel tabanlı yöntemler önerilmiştir.

Süperpikseller, bölütleme ile elde edilen, hiperspektral görüntü içerisindeki çeşitli spektral yoğunluğu ve doku yapılarını yakalayan, farklı şekil ve büyüklükteki örtüşmeyen, homojen bölgelerdir. Sabit bir uzamsal pencere yerine süperpiksellerin kullanılması, hiperspektral görüntü içerisindeki sınıf sınırlarının yakalanmasını sağlar. Ayrıca, süperpiksel tabanlı yöntemler genelde süperpiksel bazında sınıflandırma gerçekleştirmeleri sayesinde pencere tabanlı yöntemlere kıyasla daha hızlıdır [79, 80]. Buna karşın, HSG içerisinde yer alan farklı boyuttaki ve morfolojik yapıdaki sınıfları, tek bir ölçek kullanan süperpiksel tabanlı bir yöntem ile yakalamak zordur. Bunu gidermek için literatürde çok ölçekli süperpiksel tabanlı sınıflandırma yöntemleri önerilmiştir [80–83]. Çok ölçekli süperpiksel tabanlı yöntemlerde, hiperspektral görüntüden farklı ölçeklerde süperpikseller çıkarılmaktadır ve her ölçek için süperpiksel bazında sınıflandırma yapılmaktadır. Farklı ölçeklerle elde edilen etiketler piksel bazında kaynaştırılmaktadır.

Tez kapsamında uzamsal bilgilerden farklı şekillerde yararlanan gösterim tabanlı yöntemler önerilmektedir. Önerdiğimiz yöntemlerde NSC yönteminin geometrik yorumundan esinlenilmiştir. NSC yönteminin dayandığı, aynı sınıfa ait örneklerin yaklaşık olarak aynı altuzayda yer alması gerektiği varsayımı genişletilmiş ve uzamsal olarak bitişik piksellerin de

büyük olasılıkla aynı sınıfa ait olduğu varsayımı eklenmiştir. Bu iki varsayım birleştirilerek, uzamsal olarak bitişik piksellerin de yaklaşık olarak aynı altuzayda bulunması gerektiği çıkarımına varılmıştır. Önerdiğimiz sınıflandırma yaklaşımını, literatürde yer alan uzamsal bilgiden yararlanan diğer gösterim tabanlı yöntemlerden ayıran nokta da bu vardığımız çıkarım kullanılarak uzamsal bilgiden yararlanılmasıdır. Bu sayede, HSG için sınıflandırma problemi; literatürde yer alan uzamsal bilgiyi kullanan gösterim tabanlı yöntemlerden farklı olarak basitçe altuzaylar arasındaki yakınlıkların analizi problemine indirgenmiştir. Bu vardığımız çıkarıma dayanarak sınıflandırma sırasında uzamsal bilgiden yararlanırken kullanılan pikseller kümesinin kapsadığı altuzay ile sınıf içi eğitim örneklerinin kapsadığı altuzay arasındaki yakınlığı analiz ederek sınıflandırma işlemi yapan bir yaklaşım önerilmiştir. Tez kapsamında, önerilen yaklaşımı kullanan dört farklı yöntem geliştirilmiştir. Literatürde önerilen gösterim tabanlı sınıflandırma yöntemlerinin bir kısmı Şekil 1.4’te verilmiştir. Bu yöntemler arasında önerdiğimiz yöntemlerin ait olduğu dal kırmızı ile vurgulanmıştır.



Şekil 1.4 Literatürde bulunan gösterim tabanlı yöntemlerden bazıları

Tez kapsamında önerilen yöntemler müsilaj tespiti problemi için de denenmiş ve performansı literatürde bulunan yöntemlerle karşılaştırılmıştır. Müsilaj, bitki planktonlarının ve denizdeki bazı mikroorganizmaların aşırı büyümesiyle oluşan kalın, mukus benzeri bir maddedir [84]. Deniz sümüğü veya deniz salyası olarak da adlandırılmaktadır. Müsilaj seviyeleri aşırı derecede arttığında deniz yüzeyinde kalın bir tabaka oluşturur. Müsilaj deniz yüzeyinin yüzlerce kilometresini kaplayabilir ve varlığının uzun sürmesi denizlerdeki oksijen dengesini değiştirir ve deniz ekosistemi için zararlı hale gelir. Bu da biyoçeşitliliği,

balıkçılığı ve turizmi olumsuz yönde etkiler [85, 86]. Müsilaj, bu nedenle Türkiye’de ve dünyada ekolojik ve ekonomik etkileri olan önemli bir problemdir. Bu olumsuz etkileri nedeniyle, denizdeki müsilajın yayılmasını önlemek için sürekli olarak izlenmesi ve erken aşamalarda tespit edilmesi gerekir. Bu bağlamda, hiperspektral görüntüleme gibi uzaktan algılama teknikleri, hem müsilaj oluşumlarının kapsamını ve konsantrasyonunu araştırmak hem denizlerdeki hareketliliğini, meteorolojik değişiklikleri analiz etmek hem de geriye dönük olarak kontrol etmek amacıyla, müsilajın tespitinde ve değerlendirilmesinde kritik bir öneme sahiptir. Bu amaçla literatürde bu alanda bir çok çalışma yapılmıştır [84, 87]. Bu tez kapsamında da müsilajın uydu görüntüleri ile uzaktan tespiti amacıyla deneyler yapılmıştır ve önerilen yöntemler iki farklı gerçek müsilaj verisi üzerinde test edilmiştir.

1.3. Tezin Amacı

Bu çalışmadaki amacımız;

- hiperspektral görüntü sınıflandırma için uzamsal bilgiden etkili bir şekile yararlanan,
- sınırlı eğitim verisi ile iyi sonuçlar veren,
- uzun eğitim sürelerine ihtiyaç duymayan,
- zorlu parametre ayarlama süreçlerine ihtiyaç duymayan,
- uygulaması kolay

bir sınıflandırma yaklaşımı önermektir.

Önerdiğimiz spektral-uzamsal en yakın altuzay sınıflandırıcısı (Spectral-Spatial Nearest Subspace Classifier, SSNSC) yaklaşımı basit bir şekilde iki altuzay arasındaki yakınlığı analiz ederek sınıflandırma yapmaktadır. Ayrıca, hiperspektral görüntü sınıflandırma sırasında karşılaşılabilecek farklı problemler için önerilen SSNSC yaklaşımını kullanan dört farklı yöntem;

- Pencere Tabanlı En Yakın Altuzay Sınıflandırıcısı (Window Based Nearest Subspace Classifier, WBNSC),
- Süperpiksel Tabanlı En Yakın Altuzay Sınıflandırıcısı (Superpixel Based Nearest Subspace Classifier, SBNSC),
- Çok-Ölçekli Süperpiksel Tabanlı En Yakın Altuzay Sınıflandırıcısı (Multi-Scale Superpixel Based Nearest Subspace Classifier, MSBNSC),
- Çoğunluk Oylama ile Süperpiksel Tabanlı En Yakın Altuzay Sınıflandırıcısı (Superpixel Based Nearest Subspace Classifier with Majority Voting, SBNSCMV)

tez kapsamında önerilmiştir.

1.4. Tez Çalışmasının Katkıları

Bu tezin katkıları şu şekilde özetlenebilir:

- Tez kapsamında, anlamlı ve anlaşılması kolay bir geometrik yorumu olan sınıflandırma yaklaşımı önerilmiştir. Aynı sınıfa ait örneklerin yaklaşık olarak aynı altuzayda yer alması gerektiği ve uzamsal olarak bitişik piksellerin de büyük olasılıkla aynı sınıfa ait olduğu varsayımları kullanılarak bir sınıflandırma yaklaşımı geliştirilmiştir. Bu iki varsayımı birleştirerek, uzamsal olarak bitişik piksellerin de yaklaşık olarak aynı altuzayda da bulunması gerektiği çıkarımına varılmıştır. Önerdiğimiz sınıflandırma yaklaşımını, literatürde yer alan uzamsal bilgiden yararlanan diğer gösterim tabanlı yöntemlerden ayıran nokta da bu vardığımız çıkarım kullanılarak uzamsal bilgiden yararlanılmasıdır. Bu sayede, HSG için sınıflandırma problemi; literatürde yer alan uzamsal bilgiyi kullanan gösterim tabanlı yöntemlerden farklı olarak basitçe altuzaylar arasındaki yakınlıkların analizi problemine indirgenmiştir. Bu vardığımız çıkarıma dayanarak sınıflandırma sırasında uzamsal bilgiden yararlanırken kullanılan pikseller kümesinin kapsadığı altuzay ile sınıf içi eğitim örneklerinin kapsadığı altuzay arasındaki yakınlığı analiz ederek sınıflandırma işlemi yapan bir yaklaşım önerilmiştir.

- Önerdiğimiz sınıflandırma yaklaşımında sunulan optimizasyon problemini çözmek için Kanonik Korelasyon Analizi (Canonical Correlation Analysis, CCA) kullanılmaktadır ve CCA sayesinde kapalı-form bir çözüm elde edilmektedir.
- Önerdiğimiz sınıflandırma yaklaşımında uzamsal bilgiden yararlanırken kullanılan piksellerin sınıflandırmaya sağladıkları katkı tekbıçimli (uniform) değildir. Önerilen yöntemimizde bu adaptif ağırlıklar, sınıflandırılacak bölge için kullanılan uzamsal bölge içerisinde yer alan gürültülü piksellerin sınıflandırmadaki olumsuz etkilerini azaltacak şekilde otomatik olarak belirlenmektedir.
- Sunulan optimizasyon probleminde literatürde bulunan bazı yöntemlerde (RJNSC [78]) olduğu gibi ayarlanması zorlu parametreler yoktur. Bu sayede önerilen yöntem basit ve uygulaması kolaydır.
- Tez kapsamında, HSG sınıflandırma sırasında karşılaşılabilecek muhtemel problemlerle ilgilenen 4 farklı yöntem geliştirilmiş ve yöntemlerin birbirlerine ve literatürdeki yöntemlere karşı üstünlükleri/eksiklikleri beş farklı veri kümesi ile yapılan deneylerle ayrıntılı olarak tartışılmıştır.
- Tez kapsamında müsilağ tespiti problemi ile de ilgilenilmiştir. Músilağ tespiti klasik olarak denizden örnek toplanarak sonrasında bu örneklerin laboratuvar ortamına taşınması ve laboratuvar ortamında incelenmesi ile yapılmaktadır. Fakat denizlerin büyüklüğü göz önüne alındığında, müsilağ tespitinin bu tip yöntemler ile yapılması çok zahmetli bir hal almaktadır. Tez kapsamında önerilen yöntemler uydular tarafından farklı zamanlarda, farklı konumlarda toplanan hiperspektral veriler üzerinde test edilmiştir.
- Yapılan deneyler; sınırlı eğitim verisi olması durumunda önerilen yöntemlerin karşılaştırılan literatürdeki diğer yöntemlere göre daha tercih edilir yöntemler olduğunu göstermektedir. Hiperspektral görüntülerde veri toplama ve etiketleme işleminin zaman alıcı ve maliyetli olması sebebiyle eğitim verisi sayısının sınırlı olduğu düşünülürse, önerilen yöntemlerin sınırlı eğitim verisi ile elde ettiği bu başarı oldukça kıymetlidir.

Beş gerçek hiperspektral veri kümesi üzerinde yapılan deneyler, önerilen yöntemlerin uzamsal bilgiyi etkili bir şekilde kullandığını ve gürültülü piksellere (tuz ve biber gürültüsü) dayanıklı olduğunu ve sınıf sınırlarında olması muhtemel yanlış sınıflandırma problemlerinin üstesinden geldiğini göstermektedir.

1.5. Tezin Akışı

Tez toplamda beş ana bölümden oluşmaktadır. Sırasıyla “Giriş”, “Gösterim Tabanlı Yöntemler”, “Önerilen Yöntemler”, “Deneysel Çalışmalar”, “Sonuçlar ve Tartışma” bölümlerinden oluşmaktadır. Bölümlerin içerikleri aşağıdaki gibi özetlenebilir;

Bölüm 1.’de tez kapsamında ilgilendiğimiz problem hakkında bilgi verilmiştir. Tezin kapsamından, katkılarından bahsedilmiş ve son olarak tezin organizasyonu hakkında bilgi verilmiştir.

Önerdiğimiz yöntem gösterim tabanlı bir yöntemdir. Bölüm 2.’de literatürde bulunan gösterim tabanlı sınıflandırma algoritmaları ayrıntılı bir şekilde açıklanmış ve teorik altyapıları verilmiştir.

Bölüm 3.’te önerdiğimiz yöntemlerin teorisinden ve geometrik yorumundan, bu yöntemleri önermemizdeki motivasyonumuzdan bahsedilmiştir.

Bölüm 4.’te literatürde sıklıkla kullanılan üç hiperspektral veri kümesi ve Bursa ve İstanbul üzerinden alınan müsilaaj veri kümeleri üzerinde yürütülen deneyler için karşılaştırmalı sonuçlar verilmiş ve sonuçlar kapsamlı bir şekilde yorumlanmıştır.

Son kısımda yaptığımız çalışmalar ve sonuçları toparlanmış ve gelecekte yapılacak çalışmalardan bahsedilmiştir.

2. GÖSTERİM TABANLI YÖNTEMLER


Önerdiğimiz yöntemler gösterim tabanlı yöntemlerdir. Bu nedenle, bu bölümde gösterim tabanlı yöntemler hakkında genel bir bakış sunulmaktadır. Ağırlıklı olarak ilham aldığımız yöntem olan NSC ve onun uzamsal bilgiyi kullanan uzantıları üzerinde durulmaktadır. Gösterim tabanlı yaklaşımlarda; “bir test örneği, eğitim örneklerinin ağırlıklı doğrusal kombinasyonları ile yaklaşık olarak elde edilebilir.” varsayımı vardır. Bu yaklaşımlar sınıflandırma sırasında eğitim verisini kullanma şekillerine göre ikiye ayrılmaktadır. Bunlardan ilkinde yer alan yöntemler (CRC, SRC), bir test pikseli için kestirim elde etme sürecinde tüm eğitim verisini kullanılırken diğer yöntemlerde (NSC) ise test pikseli için sınıfa özgü eğitim verileri ile ayrı ayrı kestirim elde edilmeye çalışılmaktadır.

Bu bölümde ilk olarak tez süresince kullandığımız notasyonlar açıklanmıştır. Sonrasında literatürde çok farklı alanlarda sıklıkla kullanılan SRC ve CRC yöntemlerinden bahsedilmiş ve sonrasında ilham aldığımız yöntem olan NSC ve onun uzamsal bilgiyi kullanan uzantıları olan JNSC ve RJNSC yöntemleri üzerinde durulmuştur.


2.1. Notasyon

Bu kısımda tez boyunca kullanılan notasyonlardan bahsedilmektedir. $\mathbf{x}_{ij} \in R^d$, i . sınıfa ait j . eğitim örneğini ifade ederken, $\mathbf{X}_i = [\mathbf{x}_{i1}, \mathbf{x}_{i2}, \dots, \mathbf{x}_{in_i}] \in R^{d \times n_i}$, i . sınıfa ait tüm eğitim örneklerini ifade etmektedir. d spektral bant sayısını, n_i ise i . sınıfa ait eğitim örneklerinin sayısını ifade etmektedir. $\mathbf{X} = [\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_C] \in R^{d \times N}$ eğitim örneklerinin tümünü ifade ederken $N = \sum_{i=1}^C n_i$ toplam eğitim verisi sayısını, C ise sınıf sayısını ifade etmektedir. Bahsi geçen notasyonlar Şekil 2.1’de görselleştirilmiştir. Burada her bir kolon bir eğitim örneğine denk gelmektedir.

$\mathbf{y} \in R^d$ test örneğini ifade ederken $\mathbf{Y} = [\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_{n_Y}] \in R^{d \times n_Y}$ sınıflandırma sırasında uzamsal bilgidен yararlanırken kullanılan pikseller kümesidir. n_Y ise bu örneklerin sayısını ifade etmektedir. $\mathbf{y}$ ve $\mathbf{Y}$ notasyonları için görseller Şekil 2.2’de verilmiştir.



Şekil 2.1 Eğitim verisine ait notasyonlar için görseller



(a) y test pikseli

(b) Süperpiksel içerisindeki pikseller kümesi Y

Şekil 2.2 Test pikseli y ve uzamsal bilgiden yararlanmak için kullanılan piksel kümesi Y notasyonları için görseller

HSG sınıflandırma sırasında uzamsal bilgiden yararlanırken çoğu yöntem genel olarak iki farklı yaklaşımdan yararlanmaktadır. Bu yaklaşımlardan ilki, uzamsal bilgiden yararlanmak için Şekil 2.2(b)'de gösterildiği gibi test pikseli etrafında belirli sabit bir kalıp içerisinde yer alan pikselleri kullanmaktadır [33, 66, 78, 88]. Şekil 2.2(b)'de bu kalıp bir penceredir ve Y ile kastedilen de bu pencere içerisinde yer alan pikseller kümesidir. İkinci tip yöntemler ise uzamsal bilgi olarak Şekil 2.2(c)'de de görüldüğü gibi süperpiksellerden yararlanmaktadır. Burada Y ile kastedilen süperpiksel içerisindeki pikseller kümesidir.

2.2. Seyrek Gösterim Tabanlı Sınıflandırıcı (SRC)

İlk olarak yüz tanıma için önerilen seyrek gösterim tabanlı sınıflandırma (SRC) yöntemi [89], sonrasında çeşitli makine öğrenmesi uygulamalarında da büyük ilgi görmüştür [90–92]. Bu yöntemlerde, eğitim örnekleri içerisinde sadece birkaç tanesi ile test örneği için bir gösterim elde edilebileceği varsayımı vardır; yani kullanılacak eğitim verisi sayısı için bir seyreklik kısıtı vardır. Şekil 2.3'te bu varsayım görselleştirilmiştir. SRC yöntemi de diğer gösterim tabanlı yöntemlerde olduğu gibi test pikselini eğitim örneklerinin doğrusal kombinasyonları ile elde etmeye çalışmaktadır.


$$\mathbf{y} \approx \mathbf{X}\mathbf{a} \quad (1)$$

Seyrek gösterim tabanlı yöntemlerde yer alan seyreklik kısıtı hesaba katıldığında seyrek gösterim tabanlı sınıflandırma için optimizasyon problemi:

$$\hat{\mathbf{a}} = \arg \min_{\mathbf{a}} \|\mathbf{a}\|_0 \quad s.t. \quad \|\mathbf{y} - \mathbf{X}\mathbf{a}\|_2 \leq \beta \quad (2)$$

şeklinde ifade edilebilir. Burada $\|\mathbf{a}\|_0$, $\mathbf{a}$ vektörünün l_0 normunu yani $\mathbf{a}$ vektörü içerisinde yer alan sıfırdan farklı elemanların sayısını ifade etmektedir, β ise hata tolerans değerini ifade etmektedir ve sıfırdan büyüktür. Bu optimizasyon problemi çözülerek seyrek gösterimler elde edilebilmektedir. Bu optimizasyon problemi ile ilgilenen bazı yöntemlerde seyreklik kısıtı (gösterim elde etme sırasında kullanılacak maksimum eğitim verisi sayısı, s_k) algoritmaya girdi olarak alınmaktadır.

Denklem (2)'deki optimizasyon problemini çözmek için $\mathbf{y}$ test örneğini seyrek şekilde en iyi ifade edecek eğitim verileri kombinasyonlarının bulunması gerekmektedir. Bu da özellikle eğitim verisi sayısı büyük olduğu durumlarda büyük bir işlem yükünü beraberinde getirmektedir. Örneğin eğitim verisi sayısının $N = 500$ ve seyreklik kısıt değerinin $s_k = 5$ olduğunu varsayalım. Bu durumda 500 eğitim verisinin tüm 5'li kombinasyonlarının denenmesi ve $\mathbf{y}$ test pikselini en iyi ifade eden 5 tane eğitim verisinin bulunması için 255 milyarın üzerinde kombinasyonun denenmesi ve bu kombinasyonlar arasından en iyisinin bulunması gerekmektedir. Eğitim verisi ve/veya kombinasyon sayısının artması çok daha büyük



Şekil 2.3 SRC yönteminin ilgilendiği problem. Bu yöntemde seyreklik kısıtı vardır.

hesap maliyetlerine neden olacaktır. Bu yüzden literatürde bu optimizasyon problemi NP-Zor (Non-deterministic Polynomial time-Hard) olarak ifade edilmektedir [93]. Dik eşleme takip (orthogonal matching pursuit, OMP) [94], altuzay takip (subspace pursuit, SP) [95] gibi açgözlü (greedy) yöntemler ve bu yöntemlerin varyantları bu optimizasyon problemini çözmek için optimum eğitim verilerini bulmak yerine iteratif bir şekilde tüm kombinasyonları denemeden yaklaşık bir sonuç elde etmeye çalışmaktadır. Bu yöntemler pratik olmaları ve hesapsal yüklerinin düşük olması nedeniyle literatürde sıklıkla tercih edilmektedir.

Alternatif bir yaklaşım olarak l_0 normu yerine l_1 normu kullanılarak problem Denklem (3)'teki gibi dışbükey hale getirilebilmektedir:

$$\hat{\mathbf{a}} = \arg \min_{\mathbf{a}} \|\mathbf{a}\|_1 \quad s.t. \quad \|\mathbf{y} - \mathbf{X}\mathbf{a}\|_2 \leq \beta \quad (3)$$

Bu optimizasyon probleminin çözümü de seyrek bir çözüm sağlar. Bu optimizasyon probleminin çözümü, baz takip (Basis pursuit, BP) [96], en küçük mutlak daralma ve seçme operatörü (least absolute shrinkage and selection operator - LASSO) [97] vb. yöntemlerle elde edilebilir. Bu yöntemlerin de ortak dezavantajı, yüksek hesaplama karmaşıklığıdır [65]. Bu tarz yöntemler ile seyrek çözümler elde edildikten sonra bir test pikselinin sınıf etiketi,

Denklem (4)'te verildiği gibi sınıf bazında en düşük regresyon hatası olan sınıf olarak belirlenir.

$$etiket(\mathbf{y}) = \arg \min_i \|\mathbf{y} - \mathbf{X}_i \hat{\mathbf{a}}_i\|_2 \quad \forall i \in \{1, 2, \dots, C\} \quad (4)$$

Test pikseli için etiket kestirim fazı Şekil 2.7'de görselleştirilmiştir.

2.3. İşbirlikçi Gösterim Tabanlı Sınıflandırıcı (CRC)

Literatürde SRC'ye alternatif olarak hesaplama açısından daha verimli CRC yöntemi önerilmiştir [65]. Bu yöntemde Şekil 2.4'te de görselleştirildiği gibi bir seyreklik kısıtlaması yoktur ve eğitim kümesinde yer alan tüm örnekler aynı anda gösterim elde etmek için kullanılmaktadır. Bu yüzden yöntemin ismi “işbirlikçi” olarak verilmiştir. Herhangi bir kısıt olmadan test pikseli; eğitim örneklerinin doğrusal kombinasyonları şeklinde yaklaşık olarak ifade edilmeye çalışılmaktadır ($\mathbf{y} \approx \mathbf{X} \mathbf{a}$). Bu yöntem için optimizasyon problemi;


$$\hat{\mathbf{a}} = \arg \min_{\mathbf{a}} \|\mathbf{y} - \mathbf{X} \mathbf{a}\|_2^2 \quad (5)$$

olarak ifade edilmektedir. Bu optimizasyon probleminin l_2 -norm en küçük kareler yöntemi ile çözülebilmesi sayesinde

$$\hat{\mathbf{a}} = \left(\mathbf{X}^T \mathbf{X} \right)^{-1} \mathbf{X}^T \mathbf{y} \quad (6)$$

şeklinde kapalı form (closed form) bir çözümü vardır ve SRC yöntemine kıyasla çok daha düşük hesaplama maliyeti sağlamaktadır [98–100]. SRC yöntemine benzer şekilde, bahsedilen kapalı form çözümü ile $\hat{\mathbf{a}}$ katsayıları elde edildikten sonra, bir test pikselinin sınıf etiketi, Denklem (7)'deki gibi sınıf bazında en düşük regresyon hatası olan sınıfa atanmaktadır:


$$etiket(\mathbf{y}) = \arg \min_i \|\mathbf{y} - \mathbf{X}_i \hat{\mathbf{a}}_i\|_2 \quad \forall i \in \{1, 2, \dots, C\} \quad (7)$$



Şekil 2.4 CRC yönteminin ilgilendiği problem

2.4. En Yakın Altuzay Sınıflandırıcısı (NSC)

SRC ve CRC yöntemleri, bir test örneği için gösterim elde etme esnasında eğitim verisinin tümünü kullanırken NSC [67] yöntemi, Şekil 2.5'te gösterildiği gibi sınıf bazlı gösterime odaklanmaktadır. NSC yönteminde; her bir sınıf için ayrı ayrı gösterim elde etmeye çalışılması nedeniyle hesap maliyeti CRC'ye göre daha yüksektir. NSC yönteminin altında yatan ana fikir, aynı sınıfta yer alan örneklerin yaklaşık olarak aynı altuzayda yer alması varsayımıdır [67, 101]. En Yakın Altuzay Sınıflandırıcısı yönteminin isminde yer alan “alt-uzay” ifadesi, her bir sınıfa ait eğitim verisi tarafından ($X_i, \forall_i \in \{1, 2, \dots, C\}$) kapsanan altuzaya yani X_i 'nin kolon uzayına ($Col(X_i)$) denk gelmektedir.



Şekil 2.5 NSC yönteminde test pikseli için sınıfa özgü eğitim verileri ile ayrı ayrı kestirim elde edilmeye çalışılmaktadır.

Test örneğinin $\mathbf{y} \in R^d$ etiketinin l olduğunu varsayalım. NSC'deki fikre göre, $\mathbf{y}$ yaklaşık olarak l . sınıfa ait eğitim örnekleri tarafından kapsanan altuzayda yer almalıdır. Buna göre $\mathbf{y}$ Denklem (8)'deki gibi ifade edilebilir:

$$\begin{aligned}\mathbf{y} &\approx a_{l1}\mathbf{x}_{l1} + a_{l2}\mathbf{x}_{l2} + \dots + a_{ln_l}\mathbf{x}_{ln_l} \\ &\approx \mathbf{X}_l \mathbf{a}_l\end{aligned}\tag{8}$$

Burada $\mathbf{a}_l$ vektörünün içerisindeki değerler, $\mathbf{X}_l$ eğitim örneklerinin ağırlıklarına karşılık gelen katsayılardır. Denklem (8)'de etiketi l olan bir test örneği için örnek gösterilmiştir. Fakat normalde, test örneği $\mathbf{y}$ 'nin etiketi bilinmemektedir. NSC yönteminde, $\mathbf{y}$ test örneğinin etiketini tahmin etmek için, test örneği $\mathbf{y}$ ve her bir sınıf için kolon uzayı $Col(\mathbf{X}_i)$ arasındaki minimum mesafe (veya minimum artık değer) $\mathbf{r}_i = \mathbf{y} - \mathbf{X}_i \hat{\mathbf{a}}_i$ şeklinde hesaplanır. Daha sonra test örneği, en yakın altuzaya denk gelen sınıf olarak etiketlenir. Burada $\hat{\mathbf{y}}_i = \mathbf{X}_i \hat{\mathbf{a}}_i$; $Col(\mathbf{X}_i) \forall_i \in \{1, 2, \dots, C\}$ kolon uzayı içerisinde yer alan $\mathbf{y}$ vektörüne en yakın vektörü ifade etmektedir. $\hat{\mathbf{a}}_i \forall_i \in \{1, 2, \dots, C\}$ ise $\mathbf{y}$ vektörüne en yakın vektörü veren optimum katsayıları içeren vektördür. Bu katsayılar vektörü Denklem (9)'daki gibi hesaplanmaktadır:

$$\hat{\mathbf{a}}_i = \arg \min_{\mathbf{a}_i} \|\mathbf{y} - \mathbf{X}_i \mathbf{a}_i\|_2^2\tag{9}$$

Şekil 2.6'da gösterildiği gibi $Col(\mathbf{X}_i)$ içerisinde yer alan $\mathbf{y}$ test vektörüne en yakın vektör, artık değer $\mathbf{r}_i$ 'nin altuzaya dik olduğu vektördür. Bu da matematiksel olarak:

$$\mathbf{X}_i^T \mathbf{r}_i = 0\tag{10}$$


olarak ifade edilir. Bu denklemde $\mathbf{r}_i$ yerine $\mathbf{y} - \mathbf{X}_i \hat{\mathbf{a}}_i$ yazdığımızda:

$$\begin{aligned}\mathbf{X}_i^T (\mathbf{y} - \mathbf{X}_i \hat{\mathbf{a}}_i) &= 0 \\ \mathbf{X}_i^T \mathbf{X}_i \hat{\mathbf{a}}_i &= \mathbf{X}_i^T \mathbf{y}\end{aligned}\tag{11}$$

elde edilir. Buradan en uygun (optimal) katsayılar vektörü $\hat{\mathbf{a}}_i$ için Denklem (12)'deki kapalı form çözüm elde edilir:

$$\hat{\mathbf{a}}_i = \left(\mathbf{X}_i^T \mathbf{X}_i \right)^{-1} \mathbf{X}_i^T \mathbf{y} \quad (12)$$

Denklem (12)'deki kapalı form çözümü elde etmenin bir diğer yolu da $\|\mathbf{y} - \mathbf{X}_i \mathbf{a}_i\|_2^2$ ifadesinin $\mathbf{a}_i$ 'ye göre türevini almaktır.



Şekil 2.6 NSC yönteminin geometrik yorumu

Her sınıf için optimal katsayılar $\hat{\mathbf{a}}_i$ hesapladıktan sonra, test örneği ile sınıf içi eğitim örnekleri tarafından kapsanan altuzaylar arasındaki minimum Öklid mesafesi $\mathbf{r}_i = \mathbf{y} - \mathbf{X}_i \hat{\mathbf{a}}_i$ ifadesi ile her sınıf için ayrı ayrı hesaplanır. Ardından test pikseli Denklem (13)'te ifade edildiği gibi $\mathbf{y}$ etiketi, en yakın altuzaya sahip sınıfa atanır.

$$etiket(\mathbf{y}) = \arg \min_i (\|\mathbf{r}_i\|_2^2) \quad \forall_i \in \{1, 2, \dots, C\} \quad (13)$$

NSC yönteminin adımları Algoritma 1'de özetlenmiştir.

Algoritma 1 En Yakın Altuzay Sınıflandırıcısı

Girdi:

Eğitim kümesi: $\mathbf{X}_i \in R^{d \times n_i} \quad \forall_i \in \{1, 2, \dots, C\}$

Test örneği: $\mathbf{y} \in R^d$

Yöntem:

$$1 : \hat{\mathbf{a}}_i = \left(\mathbf{X}_i^T \mathbf{X}_i \right)^{-1} \mathbf{X}_i^T \mathbf{y}$$

$$2 : \mathbf{r}_i = \mathbf{y} - \mathbf{X}_i \hat{\mathbf{a}}_i$$

$$3 : \text{etiket}(\mathbf{y}) \leftarrow \arg \min_i (\|\mathbf{r}_i\|_2^2)$$

Çıktı:

Artık değerler: $\mathbf{r}_i \quad \forall_i \in \{1, 2, \dots, C\}$


Etiketi kestirimi: $\text{etiket}(\mathbf{y})$

2.5. Literatürde Yer Alan Uzamsal Bilgiden Yararlanan NSC Yöntemleri

Bu kısımda literatürde yer alan uzamsal bilgiden yararlanan NSC tabanlı yöntemlerden ortak seyrek gösterim tabanlı sınıflandırıcı (Joint Nearest Subspace Classifier, JSRC) [66], dayanıklı ortak en yakın altuzay sınıflandırıcısı (Robust Joint Nearest Subspace Classifier, RJNSC) [66], Gabor-filtreleme kullanan düzenlenmiş en yakın altuzay sınıflandırıcısı (Gabor-filtering Based Nearest Regularized Subspace Classifier, Gabor-NRS) [69] ve Markov rastgele alanı (Markov Random Field, MRF) kullanan düzenlenmiş en yakın altuzay sınıflandırıcısı (NRS-MRF) [102] yöntemlerinden bahsedilmiştir.

2.5.1. Ortak En Yakın Altuzay Sınıflandırıcısı

Literatürde yer alan ortak seyrek gösterim tabanlı sınıflandırıcı (Joint Nearest Subspace Classifier, JSRC) [66] yönteminden esinlenerek literatürde NSC'nin uzamsal bilgiyi kullanan uzantısı JNSC yöntemi önerilmiştir [78]. JNSC, diğer uzamsal bilgiyi kullanan yöntemlerde olduğu gibi uzamsal olarak yakın olan piksellerin çok benzer olduğu veya aynı sınıfa ait olduğu varsayımına sahiptir. Test pikselinin komşuluğunda küçük bir pencere içerisinde yer alan tüm pikseller için ayrı ayrı en yakın altuzay sınıflandırıcısı uygulanır ve her bir piksel



Şekil 2.7 CRC, SRC ve NSC yöntemlerinde ilgili optimizasyon problemleri çözüldükten sonra her bir sınıf için geri çatım hatası hesaplanmaktadır. Hangi sınıf için geriçatım hatası daha düşük ise test pikseli o sınıfa atanmaktadır.

için optimum katsayılar vektörü elde edilir. NSC yönteminde Denklem (9)'da görüldüğü gibi test örneği ile $\text{Col}(\mathbf{X}_i)$ arasındaki minimum mesafe aranırken, JNSC yönteminde ise Denklem (14)'te verildiği gibi $\text{Col}(\mathbf{X}_i)$ ile test örneğinin etrafındaki küçük bir komşuluk içerisindeki pencerede yer alan her piksel arasındaki minimum mesafe ve bu minimum

mesafeyi veren optimum katsayılar aranır.

$$\hat{\mathbf{A}}_i = \arg \min_{\mathbf{A}_i} \|\mathbf{Y} - \mathbf{X}_i \mathbf{A}_i\|_2^2 \quad (14)$$

Burada $\mathbf{A}_i$ her bir piksel için optimum katsayılar vektörlerinden oluşan bir matris iken $\mathbf{Y} = [\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_{n_T}]$ test pikselinin etrafındaki küçük bir komşuluk içerisinde pencerede yer alan pikselleri ifade etmektedir. Ayrıca, T pencere boyutunu ifade ederken n_Y ise pencere içerisinde yer alan piksel sayısını ifade etmektedir. Örneğin, pencere boyutu $T = 3$ olduğunda (3×3 bir bölge dikkate alınır), $n_Y = 9$ 'dur. Pencere boyutu $T = 5$ olduğunda $n_Y = 25$ olmaktadır.

JNSC yöntemi için optimum çözüm NSC yöntemi için verilen Denklem (12)'deki çözüme benzer olarak $\hat{\mathbf{A}}_i = (\mathbf{X}_i^T \mathbf{X}_i)^{-1} \mathbf{X}_i^T \mathbf{Y}$ ifadesi ile hesaplanır ve test pikseli $\mathbf{y}$ 'nin etiketi minimum mesafeye sahip sınıf olarak Denklem (15)'teki gibi tahmin edilir.

$$label(\mathbf{y}) = \arg \min_i (\|\mathbf{Y} - \mathbf{X}_i \hat{\mathbf{A}}_i\|_2^2) \quad \forall_i \in \{1, 2, \dots, C\} \quad (15)$$

Bu denklemde, test pikselinin komşuluğunda yer alan her bir piksel için yaklaşım hataları, test pikselinin etiketlenmesine eşit derecede katkıda bulunur. Bu durum, JNSC yöntemini gürültülü yada aykırı piksellere karşı hassas hale getirmektedir. Bu tarz gürültülü pikseller test pikselinin komşuluğu içerisinde yer aldığı anda test piksellerinin yanlış sınıflandırılmasına neden olmaktadır. Bu nedenle gürültülü piksellerin etrafında bulunan tüm piksellerin yanlış sınıflandırılmasına neden olmaktadır. Bu da yöntemin performansını olumsuz yönde etkilemektedir.

2.5.2. Dayanıklı Ortak En Yakın Altuzay Sınıflandırıcısı

Önceki kısımda bahsedildiği üzere JNSC yönteminde test pikselinin uzamsal komşuluğunda yer alan pikseller sınıflandırmaya eşit katkı sağlamaktadır. Fakat bu yöntemdeki eşit katkı varsayımı, test pikselinin komşuluğunda aykırı ya da gürültülü piksellerin varlığı durumunda JNSC yönteminin performansını olumsuz yönde etkilenmektedir. Test pikselinin

komşuluğunda yer alan bu aykırı piksellerin olumsuz etkilerini hafifletmek için literatürde RJNSC yöntemi önerilmiştir [78].

RJNSC yönteminde en az yumuşak eşikli kareler (least soft-threshold squares method) [103] yönteminden yararlanılmaktadır. Bu yöntemde, optimizasyon problemi Denlem (16)'daki gibi tanımlanmaktadır:

$$\arg \min_{\mathbf{A}_i, \mathbf{E}} \left\{ \frac{1}{2} \|\mathbf{Y} - \mathbf{X}_i \mathbf{A}_i - \mathbf{E}\|_F^2 + \lambda \|\mathbf{E}\|_1 \right\} \quad (16)$$

burada $\mathbf{A}_i$ katsayılar matrisini, λ düzenleme parametresini, $\mathbf{E}$ ise Laplacian gürültü terimini ifade etmektedir. Düzenleme parametresi λ , sınıflandırmadaki aykırı değerlerin etkilerini azaltmak için kullanılmaktadır. Bununla birlikte, düzenleme parametresi el ile (manuel) ayarlanmaktadır. Fakat, bu düzenleme parametresinin değerini belirlemek genellikle zordur. Bu parametrenin ayarlanmasındaki zorluk, bu yöntemi verimsiz hale getirmektedir. Ayrıca, bu parametre ile gürültülü piksellerin etkisinin bastırılacağı da garanti edilmemektedir.

$\hat{\mathbf{A}}_i$ ve $\hat{\mathbf{E}}$ için optimal değerler yinelemeli olarak iki temel adım uygulanarak elde edilmektedir. İlk olarak, en küçük kare denklemi (Least-square method) $\hat{\mathbf{A}}_i = \left(\mathbf{X}_i^T \mathbf{X}_i \right)^{-1} \mathbf{X}_i^T (\mathbf{Y} - \mathbf{E})$ çözülür ve $\hat{\mathbf{A}}_i$ elde edilir. Daha sonra $\hat{\mathbf{E}} = S_\lambda(\mathbf{Y} - \mathbf{X}_i \hat{\mathbf{A}}_i)$ çözülerek $\mathbf{E}$ elde edilir. Burada $S_\lambda(\beta) = \max(\beta - \lambda, 0) \operatorname{sgn}(\beta)$ yumuşak eşikleme (soft-thresholding) işlemini ifade ederken $\operatorname{sgn}(\cdot)$ da signum fonksiyonunu ifade etmektedir. Bu bahsedilen yinelemeli süreç yakınsama olana kadar veya durdurma kriteri (örneğin, yineleme sayısı) sağlanana dek devam eder. Burada, durdurma kriterini seçmek ve durdurma kriteri değerlerini belirlemek manuel olarak ayarlanması gereken parametrelerdir ve bu parametrelerin doğru şekilde ayarlanması da zordur. Bu şekilde çözüm elde edildikten sonra $\mathbf{y}$ 'nin etiketi Denklem (17)'de gösterildiği gibi minimum mesafeye sahip olan sınıf olarak tahmin edilir:

$$\operatorname{class}(\mathbf{y}) = \arg \min_i \left\{ \|\mathbf{Y} - \mathbf{X}_i \hat{\mathbf{A}}_i - \hat{\mathbf{E}}\|_F^2 - \lambda \|\hat{\mathbf{E}}\|_1 \right\} \quad (17)$$

2.5.3. Uzamsal Bilgiyi Kullanan Diğer NSC tabanlı yöntemler

Bahsedilen spektral-uzamsal yöntemlere ek olarak, Gabor-NRS [69] ve NRS-MRF [102] yöntemleri de uzamsal bilgiyi NRS sınıflandırıcısı ile birleştirmek için literatürde önerilen yöntemlerdir. Yukarıda belirtilen yöntemlerden farklı olarak, bu yöntemler uzamsal bilgiyi ön işleme veya işlem sonrası aşamalarında kullanmaktadır.

Gabor-NRS yönteminde, Gabor filtrelemesi kullanılarak hiperspektral görüntüden uzamsal öznitelikler çıkarılmaktadır ve daha sonra bu öznitelikler NRS sınıflandırıcısında kullanılmaktadır. NRS-MRF yönteminde ise, öncelikle piksel bazında NRS yöntemi kullanılarak sınıflandırması yapılmakta; daha sonra, MRF tarafından elde edilen uzamsal bilgi NRS ile elde edilen sınıflandırma performansını iyileştirmek için kullanılmaktadır. Bu tarz spektral-uzamsal sınıflandırıcılar etkilidir, ancak ön-işleme (pre-processing) ve son işleme (post processing) aşamaları beraberinde ekstra parametreler, veriler (öznitelikler) ve karmaşıklık getirmektedir. Bu tarz yöntemlerin performansları bu değişkenlere duyarlı olduğu için bu ekstra aşamalar dikkatli bir şekilde tasarlanmalı ve ekstra parametreler doğru şekilde ayarlanmalıdır. Bu kısımda bahsedilen uzamsal bilgiyi kullanan NSC tabanlı yöntemlerin eksiklikleri Tablo 2.1’de özetlenmiştir.

Tablo 2.1 Literatürde yer alan uzamsal bilgiyi kullanan NSC tabanlı yöntemlerin eksiklikleri

Yöntemler	Eksiklikleri
JNSC	Y içerisinde yer alabilecek aykırı değerlere karşı dayanıklı değildir.
RJNSC	Gürültülü piksellerin etkisini bastırmak için bir düzenleme parametresi içermektedir. Ancak, bu parametrenin ayarlanması zordur. Ayrıca ilgili optimizasyon probleminin çözümü için uygulanan iteratif süreçte kullanılan durdurma kriteri parametrelerinin ayarlanması da zordur.
Gabor-NRS, NRS-MRF	Bu yöntemler ön-işleme son-işleme gibi ekstra aşamalar içermektedir. Bu ekstra aşamalar, beraberinde ekstra tasarım, ayarlanması gereken parametreler, yani ekstra karmaşıklık getirmektedir.


3. ÖNERİLEN YÖNTEMLER

Bu bölümde önerdiğimiz yöntemlerin teorisinden, geometrik yorumundan ve bu yöntemleri önermemizdeki motivasyonumuzdan bahsedilmiştir.

3.1. Motivasyon

Uzamsal bilgiyi kullanan NSC tabanlı yöntemlerin eksiklikleri Tablo 2.1’de özetlenmiştir. Tez kapsamında, yöntemlerin bahsedilen eksikliklerini gidermeyi amaçlayan, uzamsal bilgiden etkili bir şekilde yararlanan, geometrik yorumu kolay ve anlaşılır, uygulaması pratik bir yaklaşım sunulmuştur. Önerdiğimiz spektral-uzamsal en yakın altuzay sınıflandırıcısı (Spectral-Spatial Nearest Subspace Classifier, SSNSC) yaklaşımı basit bir şekilde iki tane altuzay arasındaki yakınlığı analiz ederek sınıflandırma yapmaktadır. Tez kapsamında bu yaklaşımı kullanan farklı yöntemler önerilmiştir. Bu yöntemler uzamsal bilgiyi kullanma şekillerine göre ikiye ayrılmaktadır. Önerilen WBNSC yöntemi uzamsal bilgi olarak test pikseli komşuluğunda yer alan uzamsal bir pencere içerisinde yer alan piksellerden yararlanırken, SBNSC yöntemi süperpiksellerden yararlanmaktadır. Bu iki yönteme ek olarak SBNSC yönteminin iki farklı uzantısı da bu tez kapsamında önerilmiştir. Önerilen bu yöntemlere ait kategorizasyon Şekil 3.1’de verilmiştir.

Bölüm 2.5.1.’de belirtildiği gibi, JNSC yönteminde uzamsal bilgiden yararlanmak için kullanılan test pikselinin komşuluğunda yer alan pikseller sınıflandırmaya eşit oranda katkı sağlarken; önerilen sınıflandırma yaklaşımında uzamsal bilgiden yararlanırken kullanılan bu piksellerin sınıflandırmaya sağladıkları katkı tekbiçimli değil, adaptiftir. Bu adaptif ağırlıklar, uzamsal bölge içerisinde yer alan gürültülü piksellerin sınıflandırmada sırasındaki olumsuz etkilerini azaltacak şekilde otomatik olarak belirlenmektedir. Bu nedenle, JNSC, gürültülü piksellere duyarlıyken önerdiğimiz yöntemler bu piksellere karşı daha dayanıklıdır. Ayrıca, önerilen yöntemlerde yer alan amaç fonksiyonu herhangi bir düzenleme parametresi içermemektedir ve bu sayede önerdiğimiz yaklaşım, RJNSC yönteminde olduğu gibi ayarlaması zor parametreler içermemektedir.



Şekil 3.1 Tez kapsamında önerilen yöntemlerin kategorizasyonu. Önerilen SSNSC yaklaşımı kullanılarak dört farklı yöntem geliştirilmiştir. Bu yöntemler arasında WBNSC yöntemi uzamsal bilgi olarak test pikseli komşuluğu içerisinde yer alan uzamsal bir pencere içerisindeki piksellerden yararlanırken, SBNSC yöntemi ise süperpiksel içerisinde yer alan piksellerden yararlanmaktadır. Ayrıca, SBNSC yönteminin iki farklı uzantısı: MSBNSC ve SBNSCMV yöntemleri de tez kapsamında önerilmiştir.

Gabor-NRS ve NRS-MRF yöntemleri sırasıyla ön işleme ve son işleme aşamalarında uzamsal bilgiyi kullanır. Bu spektral-uzamsal sınıflandırıcılar etkili yöntemlerdir, ancak ekstra ön işleme ve son işleme aşamalarında kullanılan Gabor filtreleme ve MRF de başlı başına birer yöntemdir. Bu yöntemler beraberinde ek parametreler, ek öz nitelikler yani ekstra karmaşıklıklar getirmektedir. Bu ekstra aşamaları kullanan yöntemlerin performansı bu ek faktörlerden etkilenebileceğinden, bu ekstra aşamalar da dikkatli bir şekilde tasarlanmalıdır ve ekstra aşamalar içerisinde kullanılan parametreler de doğru ayarlanmalıdır. Önerilen WBNSC yönteminde uzamsal bilginin kullanılması sürecinde ek bir ön işleme ve son işleme aşamasının olmaması, yöntemin uygulanmasını basit bir hale getirmektedir. Bu yöntemde uzamsal bilgiden yararlanırken test örneğinin komşuluğunda bir pencere içerisinde yer alan piksellerden kullanılmaktadır. Bu yöntemde ayarlanması gereken tek parametre pencere boyutudur. Bu parametre bazı basit ön bilgiler sayesinde kolaylıkla ayarlanabilmektedir. Önerilen SBNSC, MSBNSC ve SBNSCMV yöntemlerinde ise uzamsal bilgiden yararlanmak için süperpikseller kullanılmaktadır. Bu yöntemlerde ekstra bir süperpiksel elde edilme

aşaması vardır. Bu aşamada da belirlenmesi gereken tek parametre süperpiksel sayısıdır. Süperpiksel sayısının ayarlanması için de bu tez kapsamında bazı önerilerde bulunulmuştur, bunlar deneyler kısmında ayrıntılı olarak verilmiştir.

NSC yöntemi sınıflandırma sırasında sadece spektral bilgiyi kullanmaktadır. Önerdiğimiz yöntemlerde ise uzamsal bilgiden de yararlanılmaktadır. Bu tez kapsamında Y ile ifade edilen, sınıflandırma sırasında uzamsal bilgiden yararlanırken kullanılan pikseller kümesidir. Y ile kastedilen pikseller kümesi önerilen yöntemde göre değişmektedir. Önerdiğimiz süperpiksel tabanlı yöntemlerde Y ile kastedilen bir süperpiksel içerisinde yer alan pikseller kümesi iken, önerdiğimiz pencere tabanlı yöntemde ise Y ile kastedilen test pikselinin uzamsal komşuluğunda belirli bir boyuttaki pencere içerisinde yer alan piksellerdir.

Bölüm 2.4.'te bahsedildiği gibi NSC yönteminde aynı sınıfa ait örneklerin yaklaşık olarak aynı altuzayda yer alması gerektiği varsayımı bulunmaktadır. Bu varsayıma dayanarak test örneği y ile her bir sınıfa ait eğitim örneklerinin kapsadığı altuzay $Col(X_i) \forall i \in \{1, 2, \dots, C\}$ arasındaki minimum uzaklık değerleri her bir sınıf için ayrı ayrı bulunmaktadır. Test örneği hangi sınıfın eğitim örneklerinin kapsadığı altuzaya daha yakınsa test pikseli o sınıfa aittir. Önerilen sınıflandırma yaklaşımında ise NSC yöntemindeki, aynı sınıfa örneklerin yaklaşık olarak aynı altuzayda yer alması gerektiği varsayımına ek olarak, uzamsal olarak bitişik piksellerin de büyük olasılıkla aynı sınıfa ait olduğu varsayımı yapılmaktadır. Bu iki varsayımı birleştirerek, uzamsal olarak bitişik piksellerin de yaklaşık olarak aynı altuzayda bulunması gerektiği sonucuna varılmaktadır. Bu varsayımlarla birlikte, Y 'nin içerisinde yer alan piksellerin kapsadığı altuzay $Col(Y)$ ile her bir sınıfa ait eğitim örneklerinin kapsadığı altuzay $Col(X_i) \forall i \in \{1, 2, \dots, C\}$ 'ın yakınlığı analiz edilerek sınıflandırma yapılmaktadır. Y 'nin içerisinde yer alan piksellerin kapsadığı altuzay hangi sınıfın eğitim örneklerinin kapsadığı altuzaya daha yakınsa etiket kestirimi o sınıf olmaktadır.

Şekil 2.6'da görüldüğü üzere NSC yönteminde, $Col(X_i)$ altuzayı içerisindeki test örneğine en yakın olan vektör aranmaktadır. Önerdiğimiz sınıflandırma yaklaşımında ise uzamsal bilgi de dikkate alınmaktadır ve iki altuzay arasındaki yakınlık analiz edilmektedir. Şekil 3.2(a)'da görüldüğü üzere sırasıyla $Col(X_i)$ ve $Col(Y)$ içerisinde yer alan maksimum korelasyonlu

vektör çiftleri $v_{x_i} = \mathbf{X}_i \hat{\mathbf{a}}_i$

$$\hat{a}_{i1} \mathbf{x}_{i1} + \hat{a}_{i2} \mathbf{x}_{i2} + \cdots + \hat{a}_{in_i} \mathbf{x}_{in_i} = \mathbf{X}_i \hat{\mathbf{a}}_i$$

ve $v_{y_i} = \mathbf{Y} \hat{\mathbf{b}}_i$

$$\hat{b}_{i1} \mathbf{y}_1 + \hat{b}_{i2} \mathbf{y}_2 + \cdots + \hat{b}_{im} \mathbf{y}_m = \mathbf{Y} \hat{\mathbf{b}}_i$$

aranmaktadır. Şekil 3.2(a)'da ifade edildiği gibi $\hat{\mathbf{a}}_i$ ve $\hat{\mathbf{b}}_i$ vektörleri sırasıyla $Col(\mathbf{X}_i)$ ve $Col(\mathbf{Y})$ altuzayları içerisinde yer alan maksimum korelasyonlu vektör çiftlerini veren optimal katsayı vektörleridir. $\hat{\mathbf{b}}_i$ katsayıları test pikselinin komşuluğunda yer alan piksellerin sınıflandırmaya farklı oranlarda katkıda bulunmasını sağlamaktadır. JNSC yönteminde test pikselinin komşuluğunda yer alan pikseller sınıflandırmaya eşit oranda katkı sağlarken önerilen yöntemlerimizde ise komşulukta yer alan farklı pikseller için farklı farklı ağırlıklar elde edilmektedir. Bu adaptif ağırlıklar yukarıda belirtilen iki altuzay içerisinde yer alan maksimum korelasyonlu vektör çiftlerini verecek şekilde otomatik olarak elde edilmektedir. Önerilen sınıflandırma yaklaşımında altuzaylar içerisindeki maksimum korelasyonlu vektör çiftlerinin aranması sayesinde, $\mathbf{Y}$ içerisinde yer alıp eğitim örnekleriyle korele olmayan piksellerin katkıları daha az olmaktadır. Bu sayede, $\mathbf{Y}$ içerisinde yer alan gürültülü piksellerin olumsuz etkileri otomatik olarak bastırılabilir.

Daha önceden de bahsedildiği gibi önerdiğimiz sınıflandırma yaklaşımı iki altuzay arasındaki en yakın uzaklığı ölçerek sınıflandırma yapmaktadır. İki altuzay arasındaki uzaklığı ölçmenin çeşitli yolları vardır [104, 105]. Tez kapsamında iki altuzay arasındaki uzaklığı bulmak için uzaklık metriği olarak korelasyon kullanılmıştır. Bahsedilen varsayımlara dayanarak, $Col(\mathbf{Y})$ altuzayı, $Col(\mathbf{X}_i) \forall i \in \{1, 2, \dots, C\}$ altuzaylarından hangisine daha yakınsa - hangisinde maksimum korelasyonlu vektör çiftleri arasındaki korelasyon değeri maksimum ise - test pikseli o sınıfa atanmaktadır. Bu varsayımlarla birlikte, her bir sınıf için sırasıyla $Col(\mathbf{X}_i)$ ve $Col(\mathbf{Y})$ içerisinde yer alan maksimum korelasyonlu vektör çiftleri $v_{x_i} = \mathbf{X}_i \hat{\mathbf{a}}_i$ ve $v_{y_i} = \mathbf{Y} \hat{\mathbf{b}}_i$ ve bu maksimum korelasyonlu vektörleri veren $\hat{\mathbf{a}}_i$ ve $\hat{\mathbf{b}}_i$ optimal katsayıları

aranmaktadır. Bu katsayılar ve korelasyon değerleri Denklem (18)'deki optimizasyon problemi çözülerek bulunabilir:


$$\begin{aligned} \arg \max_{\mathbf{a}_i, \mathbf{b}_i} \rho_i &= \frac{\mathbf{v}_{x_i}^T \mathbf{v}_{y_i}}{\|\mathbf{v}_{x_i}\| \cdot \|\mathbf{v}_{y_i}\|} \quad \forall_i \in \{1, 2, \dots, C\} \\ &= \frac{\mathbf{a}_i^T \mathbf{X}_i^T \mathbf{Y} \mathbf{b}_i}{\|\mathbf{X}_i \mathbf{a}_i\|_2 \cdot \|\mathbf{Y} \mathbf{b}_i\|_2} \end{aligned} \quad (18)$$

CCA yöntemi bu optimizasyon problemi ile daha önceden ilgilenmiştir [106]. Önerdiğimiz sınıflandırma yaklaşımında, iki altuzay arasındaki en yakın uzaklığı ölçmek için CCA yönteminden yararlanılmaktadır. İki altuzay arasındaki en yakın uzaklığı bulmak için benzerlik ölçüsü olarak korelasyon kullanılmaktadır. Şekil 3.2(b)'de de görselleştirildiği gibi, CCA yöntemine girdi olarak sınıf içi eğitim örnekleri ve sınıflandırmada kullanılan uzamsal bilgi içerisinde yer alan piksel kümesi verilmektedir. Çıktı ise $Col(\mathbf{X}_i)$ ve $Col(\mathbf{Y})$ içerisinde yer alan maksimum korelasyonlu vektör çifti arasındaki korelasyon değeridir. Bir sonraki bölümde CCA yönteminden detaylıca bahsedilmiştir.

3.2. Kanonik Korelasyon Analizi (CCA)

Hotelling tarafından 1936 yılında geliştirilen kanonik korelasyon analizi, başlangıçta birden çok değişkenden oluşan veri kümeleri arasındaki ilişki yapısının analizi ve modellenmesi için kullanılmıştır [107]. CCA'nın istatistik [108, 109], makine öğrenmesi [110–114], görüntü işleme [115], sistem tanıma [116, 117] uygulamalarının da yer aldığı geniş bir kullanım alanı vardır. CCA, HSG sınıflandırma için de kullanılmıştır [118, 119]. Fakat, bu tez kapsamında önerilen bakış açısı literatürdekilerden tamamen farklıdır. Tez kapsamında önerdiğimiz yöntemler içerisinde sunduğumuz CCA kullanım bakış açısı literatürde ilktir. Önceki çalışmalarda çok görüşlü öğrenme kapsamı altında birden fazla bakıştan (öznitelikten) birlikte yararlanarak daha iyi gösterimlerin öğrenilmesi ve kaynaştırılmış özniteliklerin çıkarılması için CCA'dan yararlanılmıştır [118, 119].

Tez çalışması kapsamında ise CCA, Denklem (18)'de formülize edildiği gibi sırasıyla $Col(\mathbf{X}_i)$ ve $Col(\mathbf{Y})$ altuzayları içerisinde yer alan maksimum korelasyonlu $\mathbf{v}_{x_i} = \mathbf{X}_i \hat{\mathbf{a}}_i$



Şekil 3.2 Önerilen SSNSC yaklaşımının geometrik yorumu ve bu yaklaşımda CCA yönteminin kullanım şekli.

ve $\mathbf{v}_{y_i} = \mathbf{Y}\hat{\mathbf{b}}_i$ vektör çiftlerini aramak için kullanılmaktadır. Bu denklem Denklem (19)'daki gibi yeniden yazılabilir:

$$\arg \max_{\mathbf{a}_i, \mathbf{b}_i} \rho_i = \frac{\mathbf{a}_i^T \mathbf{C}_{\mathbf{X}_i \mathbf{Y}} \mathbf{b}_i}{\sqrt{(\mathbf{a}_i^T \mathbf{C}_{\mathbf{X}_i} \mathbf{a}_i)} \sqrt{\mathbf{b}_i^T \mathbf{C}_{\mathbf{Y}} \mathbf{b}_i}} \quad (19)$$

Bu eşitlikte $\mathbf{C}_{\mathbf{X}_i \mathbf{Y}} = \mathbf{X}_i^T \mathbf{Y}$ çapraz kovaryans matrisini, $\mathbf{C}_{\mathbf{X}_i}$ ve $\mathbf{C}_{\mathbf{Y}}$ kovaryans matrislerini ifade etmektedir. Korelasyon ölçek değişmezdir, bu nedenle $Col(\mathbf{X}_i)$ ve $Col(\mathbf{Y})$ altuzayları

içerisinde aynı maksimum korelasyon değerine sahip sonsuz vektör çifti bulunabilir. Tek bir çözüm elde edebilmek için, bulunacak vektör çiftleri için birim norma sahip olmaları kısıtı eklenerek problem Denklem (20)'deki gibi bir kısıtlı bir optimizasyon problemi olarak yeniden formüle edilebilir [120]:

$$\begin{aligned} \arg \max_{\mathbf{a}_i, \mathbf{b}_i} \rho_i &= \mathbf{a}_i^T \mathbf{C}_{\mathbf{X}_i \mathbf{Y}} \mathbf{b}_i \\ \text{s.t. } \mathbf{a}_i^T \mathbf{C}_{\mathbf{X}_i} \mathbf{a}_i &= \mathbf{b}_i^T \mathbf{C}_{\mathbf{Y}} \mathbf{b}_i = 1 \end{aligned} \quad (20)$$

Bu problem Denklem (21)'deki gibi Lagrange çarpanları tekniği kullanılarak çözülebilmektedir:

$$\mathcal{L} = \mathbf{a}_i^T \mathbf{C}_{\mathbf{X}_i \mathbf{Y}} \mathbf{b}_i - \frac{\lambda_1}{2} (\mathbf{a}_i^T \mathbf{C}_{\mathbf{X}_i} \mathbf{a}_i - 1) - \frac{\lambda_2}{2} (\mathbf{b}_i^T \mathbf{C}_{\mathbf{Y}} \mathbf{b}_i - 1) \quad (21)$$

Burada λ_1 ve λ_2 Lagrange çarpanlarıdır. $\mathcal{L}$ 'nin $\mathbf{a}_i$ and $\mathbf{b}_i$ 'ye göre türevi alındığında;

$$\frac{\partial \mathcal{L}}{\partial \mathbf{a}_i} = \mathbf{C}_{\mathbf{X}_i \mathbf{Y}} \mathbf{b}_i - \lambda_1 \mathbf{C}_{\mathbf{X}_i} \mathbf{a}_i = 0 \quad (22)$$

$$\frac{\partial \mathcal{L}}{\partial \mathbf{b}_i} = \mathbf{C}_{\mathbf{Y} \mathbf{X}_i} \mathbf{a}_i - \lambda_2 \mathbf{C}_{\mathbf{Y}} \mathbf{b}_i = 0 \quad (23)$$

ve sırasıyla Denklem (22) ve (23) soldan $\mathbf{a}_i^T$ ve $\mathbf{b}_i^T$ ile çarpıldığında:

$$\begin{aligned} \mathbf{a}_i^T \mathbf{C}_{\mathbf{X}_i \mathbf{Y}} \mathbf{b}_i - \lambda_1 (\mathbf{a}_i^T \mathbf{C}_{\mathbf{X}_i} \mathbf{a}_i) &= 0 \\ \mathbf{b}_i^T \mathbf{C}_{\mathbf{Y} \mathbf{X}_i} \mathbf{a}_i - \lambda_2 (\mathbf{b}_i^T \mathbf{C}_{\mathbf{Y}} \mathbf{b}_i) &= 0 \end{aligned} \quad (24)$$

ve Denklem (20)'deki kısıtlar Denklem (24)'te yerine koyulduğunda;

$$\lambda_1 = \lambda_2 = \mathbf{a}_i^T \mathbf{C}_{\mathbf{X}_i \mathbf{Y}} \mathbf{b}_i = \rho_i$$

elde edilmektedir. Böylece Denklem (22) ve (23) aşağıdaki şekilde tekrar yazılabilir.

$$\mathbf{C}_{\mathbf{X}_i \mathbf{Y}} \mathbf{b}_i = \rho_i \mathbf{C}_{\mathbf{X}_i} \mathbf{a}_i \quad (25)$$

$$\mathbf{C}_{\mathbf{Y} \mathbf{X}_i} \mathbf{a}_i = \rho_i \mathbf{C}_{\mathbf{Y}} \mathbf{b}_i \quad (26)$$

bu denklem $C_1 w = \rho_i C_2 w$ formunda Denklem (27)'deki gibi bir genelleştirilmiş özdeğer-özvektör problemine eşdeğerdir [121].

$$\begin{bmatrix} 0 & C_{X_i Y} \\ C_{Y X_i} & 0 \end{bmatrix} \begin{bmatrix} a_i \\ b_i \end{bmatrix} = \rho_i \begin{bmatrix} C_{X_i} & 0 \\ 0 & C_Y \end{bmatrix} \begin{bmatrix} a_i \\ b_i \end{bmatrix} \quad (27)$$

Denklem (18)'de formüle edilen maksimizasyon probleminin çözümü artık verilen genelleştirilmiş özdeğer probleminin çözümüne eşdeğerdir. Genelleştirilmiş özdeğer probleminin çözümü ile elde edilen en büyük özdeğer ($\max(\rho_i)$), sırasıyla $Col(X_i)$ ve $Col(Y)$ altuzaylarında yer alan maksimum korelasyona sahip vektör çifti $v_{x_i} = X_i a_i$ ve $v_{y_i} = Y b_i$ arasındaki korelasyon değerini ρ_i vermektedir. CCA yöntemi ile elde edilen bu korelasyon değerleri literatürde kanonik korelasyon olarak isimlendirilmektedir. Bu genelleştirilmiş özdeğer-özvektör problemi farklı şekillerde çözülebilmektedir [122, 123]. Bu tez kapsamında bu çözümlerden bir tanesinden bahsedilecektir. Denklem (27) 'deki matris ve vektörler kolaylık olması açısından aşağıdaki gibi ifade edildiğinde;

$$C_1 = \begin{bmatrix} 0 & C_{X_i Y} \\ C_{Y X_i} & 0 \end{bmatrix}, \quad C_2 = \begin{bmatrix} C_{X_i} & 0 \\ 0 & C_Y \end{bmatrix}, \quad w = \begin{bmatrix} a_i \\ b_i \end{bmatrix} \quad (28)$$

Denklem (27) aşağıdaki gibi ifade edilebilir.

$$C_1 w = \rho_i C_2 w \quad \Rightarrow \quad (C_1 - \rho_i C_2) w = 0 \quad (29)$$

Bu denklem, bir doğrusal denklem sistemine (system of linear equations) karşılık gelmektedir ve bu denklemin bir çözümünün olması için aşağıdaki şartı sağlamalıdır:

$$\det(C_1 - \rho_i C_2) = 0 \quad (30)$$

Burada $\det(.)$ determinant matrisini ifade etmektedir. Bu denklem çözüldüğünde özdeğer için n_i sayıda farklı çözüm elde edilmektedir. Elde edilen bu n_i çözümden sadece ilki (maksimum olanı) bu tez kapsamında dikkate alınmaktadır. En büyük özdeğer bize ρ_i 'yi yani bizim


aradığımız iki altuzay içerisinde yer alan maksimum korelasyonlu iki vektör arasındaki korelasyon değerini vermektedir. Elde edilen ρ_i değeri Denklem (29)'da yerine koyulup eşitlik çözüldüğünde elde edilen özvektör değeri de bize $\hat{\mathbf{a}}_i$ ve $\hat{\mathbf{b}}_i$ optimal katsayılar vektörlerini vermektedir. Elde edilen optimal katsayılar kullanılarak doğrusal kombinasyonlar ($\mathbf{v}_{x_i} = \mathbf{X}_i \hat{\mathbf{a}}_i$ ve $\mathbf{v}_{y_i} = \mathbf{Y} \hat{\mathbf{b}}_i$) hesaplanarak altuzaylar $Col(\mathbf{X}_i)$ ve $Col(\mathbf{Y})$ içerisinde yer alan maksimum korelasyonlu $\mathbf{v}_{x_i}$ ve $\mathbf{v}_{y_i}$ vektörleri elde edilir.

3.3. Spektral-Uzamsal En Yakın Altuzay Sınıflandırıcıları

Önceki bölümlerde yöntemleri önermemizdeki motivasyonumuzdan, önerilen yöntemlerin altında yatan geometrik anlamdan, bu anlama bağlı olarak önerilen optimizasyon probleminde, önerilen optimizasyon problemini çözmek için CCA yöntemini kullandığımızdan ve CCA yönteminin matematiğinden ayrıntıları ile bahsedilmiştir. Yine önceki kısımlarda ayrıntıları ile bahsedildiği gibi önerdiğimiz yöntemler basitçe iki altuzay arasındaki yakınlığa bakarak bir etiket kestirimi yapmaktadır. İlk olarak bu yakınlığı analiz ederek etiket kestirimi yapan Spektral-Uzamsal En Yakın Altuzay Sınıflandırıcı (Spectral-Spatial Nearest Subspace Classifier, SSNSC) yaklaşımı bu tez kapsamında sunulmaktadır. Tez kapsamında önerilen tüm yöntemler bu yaklaşımı kullanmaktadırlar.

Önerilen SSNSC yaklaşımı için girdiler, eğitim kümesi $\mathbf{X}_i \in R^{d \times n_i} \forall i \in \{1, 2, \dots, C\}$ ve sınıflandırma sırasında uzamsal bilgiden yararlanmak için kullanılan pikseller kümesi $\mathbf{Y}$ 'dir. Algoritma çıktısı her bir sınıf için bulunan korelasyon değerleri ve etiket kestirimidir. Şekil 3.3'te de görselleştirildiği gibi SSNSC yaklaşımı ile CCA kullanılarak $\mathbf{Y}$ 'nin içerisinde yer alan piksellerin kapsadığı altuzay $Col(\mathbf{Y})$ ile her bir sınıfa ait eğitim örneklerinin kapsadığı altuzay $Col(\mathbf{X}_i) \forall i \in \{1, 2, \dots, C\}$ içerisinde yer alan maksimum korelasyonlu vektörler ve bunlar arasındaki korelasyon değerleri hesaplanmaktadır. Hangi sınıf için maksimum korelasyon daha büyükse etiket kestirimi o sınıf olmaktadır. Önerilen SSNSC yaklaşımının adımları Algoritma 2'de özetlenmiştir.

İlerleyen bölümlerde ayrıntıları verilecek olan önerilen yöntemler, SSNSC yaklaşımını kullanma şekillerine göre birbirlerinden ayrılmaktadır. Yöntemlerin birbirlerinden ayrıldığı ilk



Şekil 3.3 Önerilen SSNSC yaklaşımı ile etiket kestirimi

nokta uzamsal bilgiden yararlanma şeklidir. Önerdiğimiz süperpiksel tabanlı yöntemlerde uzamsal bilgiden yararlanılırken süperpikseller içerisinde yer alan pikseller kullanılmakta, pencere tabanlı yöntemde ise test pikselinin uzamsal komşuluğunda belirli bir boyuttaki pencere içerisinde yer alan piksellerden yararlanılmaktadır. Önerdiğimiz süperpiksel tabanlı yöntemlerde SSNSC'ye girdi olarak verilen Y , bir süperpiksel içerisinde yer alan pikseller iken, pencere tabanlı yöntemde ise test pikselinin uzamsal komşuluğunda belirli bir boyuttaki pencere içerisinde yer alan pikseller kümesidir.

Önerilen yöntemlerin birbirlerinden ayrıldığı diğer bir nokta şöyledir: SSNSC ile kestirilen etiket, pencere tabanlı yöntemlerde sadece test pikseline atanırken, süperpiksel tabanlı yöntemlerde ise girdi olarak verilen süperpiksel içerisinde yer alan tüm piksellere atanmaktadır. Bu yöntemler için ayrıntılar sonraki bölümlerde verilecektir.

Algoritma 2 Önerilen Sınıflandırma Yaklaşımı: SSNSC

INPUT:

Eğitim kümesi: $X_i \in R^{d \times n_i} \quad \forall_i \in \{1, 2, \dots, C\}$

Sınıflandırmada sırasında uzamsal bilgiden yararlanırken kullanılan pikseller kümesi: $\mathbf{Y}$

Yöntem:

- 1 : $\rho_i \leftarrow CCA(\mathbf{X}_i, \mathbf{Y}) \quad \forall_i \in \{1, 2, \dots, C\}$
 - 2 : $etiket \quad kestirimi \leftarrow \arg \max_i (\rho_i)$
-

OUTPUT:

Korelasyon değerleri: $\rho_i \quad \forall_i \in \{1, 2, \dots, C\}$


Etiketi kestirimi: $etiket(\mathbf{y})$ ya da $etiket(\mathbf{Y})$ (Yönteme göre test pikseli ya da test süperpikseli için etiket kestirilmektedir.)

3.3.1. Pencere Tabanlı En Yakın Altuzay Sınıflandırıcısı (WBNSC) [124]


Bölüm 3.3.'de bahsedildiği üzere literatürde bulunan yöntemler HSG sınıflandırma sırasında uzamsal bilgiden iki farklı yaklaşım kullanarak yararlanmaktadır. Bunlardan ilki sabit komşuluk kullanma yaklaşımıdır. İkincisi ise adaptif komşuluk kullanma yaklaşımıdır. Bu kısımda, önerilen Pencere Tabanlı En Yakın Altuzay Sınıflandırıcısı (Window Based Nearest Subspace Classifier, WBNSC) yöntemi sabit bir komşuluk kullanmaktadır. Önerdiğimiz bu yöntemde uzamsal bilgiden yararlanmak için Şekil 3.4'te görüldüğü gibi test pikseli $\mathbf{y}$ 'nin komşuluğundaki sabit bir pencere içerisinde yer alan piksellerden yararlanılmaktadır.

Önerilen WBNSC yönteminde bir test pikselinin nasıl sınıflandırıldığı Şekil 3.5'te görselleştirilmiştir. $\mathbf{y}$ 'nin komşuluğundaki sabit bir pencere içerisinde yer alan pikseller ($\mathbf{Y}$) SSNSC'ye girdi olarak verilerek her bir sınıf için maksimum korelasyon değerleri hesaplanmaktadır. Aşağıdaki denklemden de ifade edildiği gibi hangi sınıf için maksimum korelasyon değeri daha büyükse $\mathbf{y}$ test örneğinin sınıf etiketi o sınıf olarak etiketlenmektedir.

$$etiket(\mathbf{y}) = \arg \max_i (\rho_i) \quad \forall_i \in \{1, 2, \dots, C\} \quad (31)$$



Şekil 3.4 Önerilen WBNSC yönteminde uzamsal bilgiden yararlanırken test pikseli y 'nin komşuluğundaki sabit bir pencere içerisinde yer alan piksellerden yararlanılmaktadır.



Şekil 3.5 WBNSC yöntemi ile bir test pikselinin sınıflandırılması

Önerilen WBNSC yönteminde ayarlanması gereken zorlu parametreler yoktur. Ayarlanması gereken tek parametre uzamsal pencere boyutudur. Bu parametre görüntü hakkında edinilen bazı ön bilgiler sayesinde kolayca ayarlanabilir. Ayrıca, uzamsal bilgiden yararlanırken süperpiksel çıkarımı, öznitelik çıkarımı gibi ön işleme ya da çoğunluk oylama gibi son işleme safhaları da kullanılmamaktadır. Bu sayede, dizayn edilmesi gereken ekstra bir süreç yoktur. Bu bahsedilen avantajları sayesinde basit ve uygulaması kolay bir yöntemdir.

3.3.2. Süperpiksel Tabanlı En Yakın Altuzay Sınıflandırıcısı (SBNSC)

Önerilen WBNSC yöntemi basit ve uygulaması kolay bir yöntem olsa da sabit pencere kullanması nedeniyle bazı dezavantajları vardır. WBNSC yöntemi sahne içerisinde büyük homojen alanların olduğu durumda tercih edilebilir fakat eğer alanlar küçükse ve sınıflar birbirine yakın ise, uzamsal bilgiden yararlanmak için sabit pencere kullanımı sınıf sınırlarında yanlış sınıflandırmalara neden olabilmektedir. Ayrıca önerilen WBNSC yönteminde tek bir test pikseline etiket atayabilmek için test pikselinin komşuluğunda bir pencere içerisinde yer alan tüm pikseller kullanılmaktadır. Hiperspektral görüntülerin büyük boyutlu (bant sayısı fazla) olduğu göz önüne alındığında sadece bir pikseli sınıflandırmak için bu denli büyük verileri hesaplama sırasında kullanmak beraberinde büyük bir hesap ve zaman maliyeti getirmektedir.


Pencere tabanlı yöntemlerde karşılaşılan bu tarz eksiklikleri gidermek amacıyla araştırmacılar uyarlanabilir komşuluk kullanan yöntemler üzerinde çalışmaya odaklanmışlardır [125]. Uyarlanabilir komşuluktan yararlanmanın bir çok yolu vardır. Bunlardan bir tanesi de farklı segmentasyon yöntemleri kullanarak görüntüyü bölütlemektir. Görüntü bölütleme, dijital bir görüntü içerisinde yer alan dokusal özelliklere bakarak ya da uzamsal olarak bitişik piksellerin yoğunluk değerlerini analiz ederek görüntüyü örtüşmeyen bölgelere bölme işlemidir. Bu sayede birbirine uzamsal olarak yakın olan ve birbirine spektral anlamda benzeyen pikseller gruplandırılır. Bu grupların her birine süperpiksel denmektedir. Süperpikseller, görüntüden çıkarılan homojen piksel toplulukları olmaları nedeniyle süperpiksellerin içerisinde farklı farklı sınıflardan örnekleri barındırma ihtimalleri düşüktür. Süperpikseller, sahne içerisinde farklılık gösteren homojenliğe bağlı olarak şekil ve boyut değiştirme yeteneklerine sahip olmaları sayesinde görüntü içerisindeki morfolojik özelliklerin de çıkarılabilmesini sağlamaktadır. Ayrıca, piksellerin gruplanıp tek bir pikselmiş gibi kabul edilmesine bağlı olarak işlenecek birim sayısı azalmaktadır; bu da işlem yükünü azaltıp hız bakımından avantaj sağlamaktadır. Bahsedilen avantajlar, pencere tabanlı yöntemlerde karşılaşılan problemlere karşı önemli iyileştirmeler sağlamaktadır [79, 80].

Süperpikseller, görüntülerin yorumlanması ve anlaşılmasını kolaylaştırması ve işleme hızını artırması sayesinde görüntü işleme alanında yaygın olarak kullanılmaktadır [126, 127]. HSG işleme alanında da sınıflandırma [128–130], boyut azaltma [131, 132], bant seçimi [133, 134], hedef tespiti [83, 135, 136] ve spektral ayrıştırma [137–140] gibi çeşitli uygulamalarda süperpiksellerden başarıyla yararlanılmıştır. Literatürde kullanılan mevcut süperpiksel segmentasyon algoritmaları grafik tabanlı yaklaşımlar [141–143] ve gradyan tabanlı yaklaşımlar [144–146] olmak üzere iki kategoriye ayrılmaktadır [79]. HSG işleme alanında, grafik tabanlı yaklaşımlar arasında entropi oran segmentasyon (entropy rate segmentation, ERS) algoritması [141], gradyan tabanlı yaklaşımlar arasında ise basit doğrusal yinelemeli kümeleme (Simple Linear Iterative Clustering, SLIC) algoritması [144] en popüler ve en sık kullanılan algoritmalarındandır.


Nesne sınırlarını iyi koruyabilmesi ve düşük hesap maliyetine sahip olması nedeniyle grafik tabanlı yaklaşımlar arasından ERS [141] yöntemi ön plana çıkmaktadır [131, 147]. ERS algoritması bu yüzden süperpiksel tabanlı hiperspektral görüntü işleme alanında en popüler ve en sık kullanılan süperpiksel segmentasyon yöntemidir [131, 148, 149]. SLIC algoritması da gradyan tabanlı yaklaşımlar arasında [144] en sık kullanılan algoritmalarındandır. Tez kapsamında bu iki yöntem üzerinde durulmuş ve bu yöntemlerle elde edilen süperpikseller ile sonuçlar alınmıştır. SLIC ile elde edilen sonuçlar ERS'ye göre daha düşük olduğu için sadece ERS ile elde edilen sonuçlar tez kapsamında verilmiştir. Önerdiğimiz tüm süperpiksel tabanlı yöntemlerde süperpiksel segmentasyon algoritması olarak ERS kullanılmaktadır.

Önerilen SBNSC yönteminde süperpiksellerin çıkarılması aşaması Şekil 3.6'da görüldüğü gibi iki adımdan oluşmaktadır. İlk adımda temel bileşenler analizi (principal component analysis, PCA [150, 151]) yöntemi kullanılarak yüksek boyutlu hiperspektral görüntünün boyutu üç boyuta indirgenmektedir. Bu indirgenen görüntü üzerinden ERS yöntemi kullanılarak süperpikseller çıkarılmaktadır. Elde edilen süperpikseller Şekil 3.7'de görüldüğü gibi SSNSC yaklaşımı ile sınıflandırılmaktadır.

Şekil 3.5 ile Şekil 3.7 kıyaslandığında, önerilen WBNSC ve SBNSC yöntemlerinin birbirlerine çok benzediği görülmektedir. Fakat aralarında ufak tefek farklılıklar bulunmaktadır. Bu



Şekil 3.6 Önerilen süperpiksel tabanlı yöntemlerde süperpiksellerin elde edilmesi



Şekil 3.7 SBNSC yöntemi ile bir süperpikselin sınıflandırılması


farklardan biri WBNSC yönteminde SSNSC'ye girdi olarak test pikselinin komşuluğunda bir pencere içerisinde yer alan pikseller verilirken, SBNSC yönteminde süperpiksel içerisindeki piksellerin girdi olarak verilmesidir. Diğer bir farklılık ise SSNSC ile elde edilen etiket kestirimi WBNSC yönteminde sadece bir test pikseline atanırken SBNSC yönteminde süperpiksel içerisindeki tüm piksellere atanmasıdır. Önerilen süperpiksel tabanlı yöntemler piksel bazında sınıflandırma yapmak yerine süperpiksel bazında sınıflandırma yapmaktadır. Süperpiksel bazında sınıflandırma yapmak süperpiksel tabanlı yöntemlere sınıflandırma hızı açısından önemli bir avantaj sağlamaktadır.

3.3.3. Çok-Ölçekli Süperpiksel Tabanlı En Yakın Altuzay Sınıflandırıcısı (MSBNSC)

Hiperspektral görüntülerde yer alan sınıflar farklı boyutlarda ve morfolojik yapılarda olabilmektedir. Bölüm 3.3.2.'te de üzerinde durulduğu gibi süperpikseller bu morfolojik yapıları yakalamada önemli bir avantaj sağlasa da, sadece tek bir ölçek ile yapılan bölütleme işlemi ile bahsedilen uzamsal özelliklerin düzgün bir şekilde yakalanabilmesi zor olmaktadır. Bununla birlikte, süperpikseller için optimal süperpiksel sayısının (süperpiksel boyutunun) seçilmesi de zordur. Süperpiksellerin boyutu büyük olduğunda bir süperpiksel içerisinde farklı sınıflara ait piksellerin olma ihtimali artmaktadır. Süperpiksel boyutu küçük olduğunda ise süperpikseller uzamsal açıdan bize yeterli bilgi sağlayamamaktadır [80, 81]. Bu tarz eksiklikleri gidermek ve uzamsal bilgiden daha etkili yararlanmak için HSG işleme alanında literatürde çok-ölçekli süperpiksel tabanlı yaklaşımlar önerilmiştir [80, 82, 83, 131]. Bu yaklaşımlardan ilham alarak bu tez kapsamında da çok-ölçekli süperpiksel tabanlı en yakın altuzay sınıflandırıcısı (Multi-scale nearest subspace classifier, MSBNSC) önerilmiştir. Önerilen bu yöntem ile farklı ölçeklerde bölütleme işlemi yapılarak farklı uzamsal özelliklerin yakalanması amaçlanmaktadır.

Önerilen yöntem Şekil 3.8'de görselleştirilmiştir. Burada $N_{\bar{O}}$ uygulanan ölçek sayısını ifade etmektedir. Önerilen yöntem üç ana adımdan oluşmaktadır.

- İlk olarak Şekil 3.8'de görüldüğü gibi görüntünün boyutu PCA ile üçe indirilmektedir.
- Sonrasında ERS yöntemi kullanılarak görüntüden farklı ölçeklerde (ERS yönteminde süperpiksel sayısı parametresi farklı farklı seçilmektedir.) süperpiksel haritaları elde edilmektedir.
- Farklı ölçekler ile elde edilen bu süperpiksel haritaları içerisinde yer alan her bir süperpiksel SSNSC ile sınıflandırılmaktadır.
- Her bir ölçek için elde edilen sınıflandırma haritaları piksel bazında çoğunluk oylama ile birleştirilerek nihai sınıflandırma haritası elde edilmektedir.




Şekil 3.8 Önerilen MSBNSC yönteminin çalışma adımları

Çok-ölçekli yöntemler için de parametre (her bir ölçek için süperpiksel sayısı) belirleme işlemi önem teşkil etmektedir. Literatürde parametre değerini belirlemek için farklı stratejiler ve deneysel yaklaşımlar bulunmaktadır.

3.3.4. Çoğunluk Oylama ile Süperpiksel Tabanlı En Yakın Altuzay Sınıflandırıcısı (SBNSCMV)

Her ne kadar süperpiksellerin homojen olması beklense de süperpikseller bazı durumlarda farklı sınıflara ait örnekler de içerebilmektedir ve karışım halinde olabilmektedirler. Bununla birlikte, farklı sınıfa ait eğitim verileri arasındaki spektral benzerlik çok yüksek olduğu durumlarda, bir süperpiksel doğru sınıfa atanmak yerine benzer olan diğer sınıfa atanabilir. Bahsedilen koşullarda süperpikseller yanlış sınıflandırılabilir. Bunun önüne geçmek için bu kısımda Çoğunluk Oylama ile Süperpiksel Tabanlı En Yakın Altuzay Sınıflandırıcısı (Süperpixel Based Nearest Subspace Classifier with Majority Voting, SBNSCMV) önerilmiştir. Önerilen yöntemin adımları Şekil 3.9’da verilmiştir.




Şekil 3.9 Önerilen SBNSCMV yönteminin adımları

Önerilen yöntem 3 aşamadan oluşmaktadır.

- İlk aşamada Şekil 3.9’de görüldüğü gibi görüntünün boyutu PCA ile üçe indirildikten sonra ERS yöntemi kullanılarak görüntü üzerinde tek ölçek ile bölütleme işlemi yapılmaktadır.
- İkinci aşamada bölütleme ile elde edilen süperpikseller SSNSC ile sınıflandırılmaktadır.
- Son işleme adımında ise test süperpikseline bitişik olan süperpiksellerin kestirilen etiketlerine bakılarak çoğunluk oylama ile test süperpikselinin nihai etiketine karar verilmektedir.

Buradaki ilk iki adım SBNSC yöntemi ile aynıdır. SBNSC yöntemine ek olarak bir son işleme adımı eklenmiştir.

Şekil 3.10'da SBNSCMV yönteminin ilk iki aşaması sonrasında elde edilen iki farklı senaryo için sınıflandırma haritaları verilmiştir. Bu aşamalarda test süperpikseli ve ona bitişik olan süperpikseller için SSNSC ile sınıf etiketi elde edilmiştir. Bu aşamadan sonra son işleme adımı ile nihai etiketin kestirimi bu senaryolar üzerinden anlatılacaktır. Burada S_T sınıflandırılacak olan test süperpikselini ifade etmektedir. S_1, S_2, S_3, S_4, S_5 ise test süperpikseline bitişik olan süperpikselleri ifade etmektedir. Bu aşamada test süperpikseli ve ona bitişik olan süperpikseller için elde edilen sınıf etiketi kestirimleri oylanarak test süperpikseli için nihai sınıf kestirimine karar verilmektedir. Test süperpikselinin iki oyu, etrafındaki bitişik süperpiksellerin tek oyu vardır. Test süperpikseli, en çok oyu alan sınıfa atanmaktadır. Test süperpikselinin sınıf sınırında yer alması ihtimali durumunda yanlış sınıflandırmaya sebebiyet vermemek amacıyla test süperpikseline iki oy hakkı verilmektedir. Bu şekilde basit bir ağırlıklı oylama ile test süperpikseli için nihai etikete karar verilmektedir.



Şekil 3.10 SBNSCMV yönteminin ilk iki aşaması sonrasında elde edilen iki farklı senaryo için sınıflandırma haritaları: Bu aşamadan sonra test süperpikseli S_T 'nin nihai etiketi, kendisinin ve kendisine bitişik olan süperpiksellerin kestirilen etiketleri dikkate alınarak çoğunluk oylama ile belirlenmektedir. Son aşama (çoğunluk oylama) sonrasında Senaryo 1'de yer alan test süperpikseli için elde edilen nihai etiket C3 olarak kalmak-tayken Senaryo 2'de yer alan test süperpikseli için elde edilen nihai etiket C2 olarak değiştirilmektedir.

Şekil 3.10'da yer alan senaryolar üzerinden çoğunluk oylama son-işleme aşamasını anlatacak olursak, Senaryo 1'e baktığımızda test süperpikseli S_T , C3 sınıfına aittir; buradan C3 sınıfına iki oy gelmektedir. Test süperpikseline bitişik olan süperpikseller; S_1 , S_4 , S_5 için etiket kestirimi C3'tür; buradan C3 sınıfına üç oy daha gelmektedir. Bu sayede C3 sınıfı için toplam oy sayısı beş olmaktadır. Benzer şekilde test süperpikseline bitişik olan diğer süperpiksellerin S_2 ve S_3 için etiket kestirimleri C2'dir. Böylelikle, C2 sınıfının oy sayısı ikidir. C1 sınıfının oy sayısı ise sıfırdır. En yüksek oyu alan sınıf C3 sınıfı olması nedeniyle S_T 'nin nihai etiketi yine C3 olmaktadır. Bu senaryoda S_T süperpikselinin etiketi çoğunluk oylama son işleme aşaması ile değişmemektedir.

Senaryo 2'ye bakıldığında test süperpikseli S_T C1 sınıfına aittir; buradan C1 sınıfı için iki oy gelmektedir. Test süperpikseline bitişik olan S_5 süperpikseli etiket kestirimi C1'dir; buradan C1 sınıfına bir oy daha gelmektedir. Bu sayede C1 sınıfı için toplam oy sayısı üç olmaktadır. Benzer şekilde test süperpikseline bitişik olan diğer süperpikseller S_1 , S_2 , S_3 , S_4 için etiket kestirimi C2'dir. Böylelikle, C2 sınıfının oy sayısı dört olmaktadır. C3 sınıfının oy sayısı ise sıfırdır. En yüksek oyu alan sınıf C2 sınıfı olması nedeniyle S_T 'nin nihai etiketi C2 olmaktadır. Bu senaryoda S_T süperpikselinin etiketi çoğunluk oylama son işleme aşaması ile C1'den C2'ye güncellenmektedir.

4. DENEYSEL ÇALIŞMALAR

Bu bölümde önerilen WBNSC, SBNSC, MSBNSC, SBNSC-MV yöntemlerinin performansı beş farklı hiperspektral veri kümesi üzerinde literatürde bulunan 10 farklı yöntem ile sınıflandırma başarımı ve hesap maliyeti bağlamında karşılaştırılmıştır.

Bu bölümdeki akış içerisinde ilk olarak deneyler sırasında kullanılan beş farklı hiperspektral veri kümesi için ayrıntılı bilgi verilmiştir; sonrasında önerilen sınıflandırma yaklaşımının çalışma prensibini incelemek amacıyla sentetik veriler üzerinde deneyler yapılmıştır. Sonraki kısımlarda önerilen pencere tabanlı ve süperpiksel tabanlı yöntemlerin performanslarını, çalışma prensiplerini ayrı ayrı incelemek, daha fazla yöntemle karşılaştırma yapmak ve farklı eğitim verisi boyutları ile yöntemlerin performansını ayrıntılı olarak incelemek amacıyla deneyler iki aşamaya ayrılmıştır. İlk aşamada önerilen WBNSC yöntemi için üç veri kümesi üzerinde sınıf başına 40 eğitim verisi ile deneyler yapılmıştır. Bu yöntemin performansı literatürde bulunan spektral tabanlı yöntemler ve spektral-uzamsal tabanlı yöntemlerle karşılaştırılmıştır. İkinci aşamada ise önerilen tüm yöntemler literatürde bulunan spektral-uzamsal tabanlı yöntemler ile dört veri kümesi üzerinde sınıf başına 20 eğitim verisi ile deneyler yapılarak karşılaştırılmıştır. Bu dört veri kümesinden ikisi müsilaj veri kümesidir. Önerilen yöntemlerin çalışma prensipleri, katkıları, avantajları ve dezavantajları deneyler sırasında ayrıntılı olarak incelenmiştir ve eğitim verisi sayısının yöntemlerin sınıflandırma performansına etkisini analiz etmek amacıyla farklı eğitim verisi sayıları ile deneyler yapılmıştır. Ayrıca, sınırlı eğitim verisi ile deneyler yapılmış ve yöntemlerin performansları karşılaştırılmıştır. Yöntemlerin sınıflandırma performansı, eğitim örneklerinin sayısı sınırlı olduğunda eğitim örneklerinin seçimine çok duyarlıdır [152]. Bu nedenle, tüm deneyler sırasında rastgele seçilen farklı eğitim örnekleri ile 10 koşu için sonuçlar alınmış ve bu sonuçların ortalamaları tablolarda paylaşılmıştır. Ayrıca bu koşulardan sadece bir tanesi için yöntemlerin sınıflandırma haritaları deneyler sırasında paylaşılmıştır.

4.1. Veri Kümeleri

Önerilen sınıflandırma yöntemlerinin performansını literatürde bulunan diğer yöntemlerle karşılaştırmak ve sonuçları değerlendirmek için 5 farklı gerçek hiperspektral veri kümesi üzerinde deneyler yapılmıştır. Bu veri kümeleri; Salinas, Indian Pines, Botsvana, İstanbul müsilaaj ve Bursa müsilaaj veri kümeleridir.

Bu veri kümeleri arasından Salinas, Indian Pines ve Botsvana veri kümeleri literatürde yaygın olarak kullanılmaktadır [153]. İstanbul ve Bursa müsilaaj veri kümeleri ise literatüre yeni sunulmuş müsilaaj veri kümeleridir [87]. Veri kümelerine ait bilgiler Tablo 4.1’de özetlenmiştir. Veriler hakkında ayrıntılı bilgi ilerleyen kısımlarda verilmektedir.

Tablo 4.1 Deneyler sırasında kullanılan veri kümelerine ait bilgiler


Veri Kümesi	Sensör	Boyut	Spektral Aralık (μm)	Uzamsal Çözünürlük (m)	Bant Sayısı (İndiergenmiş)	Sınıf Sayısı	Etiketli Örnek Sayısı
Salinas	AVIRIS	$512 \times 217 \times 224$	0.4 - 2.5	3.7	204	16	54129
Indian Pines	AVIRIS	$145 \times 145 \times 224$	0.4 - 2.5	20	200	8	8504
Botsvana	HYPERION	$1496 \times 256 \times 242$	0.4 - 2.5	30	145	14	3248
İstanbul Müsilaaj	PRISMA	$350 \times 490 \times 239$	0.4 - 2.5	30	234	2	171500
Bursa Müsilaaj	PRISMA	$421 \times 571 \times 239$	0.4 - 2.5	30	234	2	223630

4.1.1. Literatürde Yaygın Olarak Kullanılan Veri Kümeleri

Deneyler sırasında kullanılan veri kümeleri arasından Salinas, Indian Pines ve Botsvana veri kümeleri literatürde yaygın olarak kullanılmaktadır [153]. Bu veri kümeleri çeşitli arazi örtüsü sınıflarından oluşmaktadır.

Indian Pines Veri Kümesi: Deneyler sırasında kullanılan veri kümelerinden ilki Indian Pines veri kümesidir. Indian Pines verisi için yapay renkli görüntü ve yer-gerçekliği görüntüsü Şekil 4.1’de verilmiştir. Indian Pines verisi; Kuzeybatı Indiana’da yer alan Indian Pines test alanı üzerinden AVIRIS sensörü kullanılarak alınmıştır. 224 banttandır, su bantları ve gürültülü bantlar atılmış ve 200 banda indirilmiştir.

Görüntü radyans verisi olarak 145×145 örnekten oluşmaktadır. Nispeten düşük uzamsal çözünürlüğe sahiptir (piksel başına 20 metre). Bu veri kümesinde gerçekte 16 sınıf




Şekil 4.1 Indian Pines verisi için yapay renkli görüntü ve yer-gerçekliği görüntüsü (Beyaz renkli bölgeler etiketsiz verileri göstermektedir.)

Tablo 4.2 Indian Pines veri kümesi etiketli örnek bilgileri

Sınıf Numarası	Sınıf İsimleri	Etiketli Örnek Sayısı
C1	Corn-notill	1428
C2	Corn-mintill	830
C3	Grass-pasture	483
C4	Hay-windrowed	478
C5	Soybean-notill	972
C6	Soybean-mintill	2455
C7	Soybean-clean	593
C8	Woods	1265
Toplam Etiketli Örnek Sayısı		8504

bulunmaktadır, fakat deneyler sırasında her bir sınıftan 40 eğitim örneği kullanıldığı için az sayıda örnek içeren (20, 23, 46, vs.) bazı sınıflar çıkarılmış ve deneylerde sadece 8 sınıf kullanılmıştır. Veri kümesinin daraltılmış versiyonunda, Tablo 4.2’de görüldüğü gibi 8 sınıftan toplamda 8504 örnek bulunmaktadır.

Salinas Veri Kümesi: Deneylerde kullanılan bir diğer veri kümesi Salinas veri kümesidir. Salinas verisi, Kaliforniya üzerinden AVIRIS sensörü kullanılarak toplanmıştır, veri 0.4 - 2.5 μm aralığından alınmıştır ve 224 banttan oluşmaktadır. Bu veri, su bantları ve gürültülü bantlardan arındırılmış ve 204 banda indirilerek deneylerde kullanılmıştır. Salinas verisine ait yapay renkli görüntü ve yer-gerçekliği görüntüsü Şekil 4.2’de yer almaktadır.




Şekil 4.2 Salinas verisi için yapay renkli görüntü ve yer-gerçekliği görüntüsü (Beyaz renkli bölgeler etiketsiz verileri göstermektedir.)

Tablo 4.3 Salinas veri kümesi etiketli örnek bilgileri

Sınıf Numarası	Sınıf İsimleri	Etiketli Örnek Sayısı
C1	Brocoli_green_weeds_1	2009
C2	Brocoli_green_weeds_2	3726
C3	Fallow	1976
C4	Fallow_rough_plow	1394
C5	Fallow_smooth	2678
C6	Stubble	3959
C7	Celery	3579
C8	Grapes_untrained	11271
C9	Soil_vinyard_develop	6203
C10	Corn_senesced_green_weeds	3278
C11	Lettuce_romaine_4wk	1068
C12	Lettuce_romaine_5wk	1927
C13	Lettuce_romaine_6wk	916
C14	Lettuce_romaine_7wk	1070
C15	Vinyard_untrained	7268
C16	Vinyard_vertical_trellis	1807
Toplam Etiketli Örnek Sayısı		54129

Görüntü radyans verisi olarak 512×217 örnekten oluşmaktadır. Yüksek uzamsal çözünürlüğe sahiptir (piksel başına 3.7 metre). Bu veri Tablo 4.3'te verildiği gibi 16 sınıftan oluşmaktadır ve veride toplamda 54129 etiketli örnek bulunmaktadır.

Botswana Veri Kümesi: Deneylerde kullanılan bir diğer veri kümesi ise Şekil 4.3'te yapay renkli görüntü ve yer-gerçekliği görüntüsü verilen Botswana veri kümesidir. Botswana veri kümesinde sınıf bölgelerinin alanları Şekil 4.3'te görüldüğü gibi küçük küçüktür. Bu yüzden, test örneklerinin etrafındaki uzamsal pencereler genellikle test örneğinin spektral bilgisi ile benzerliği olmayan, alakasız örneklerden oluşacaktır. Bu veri kümesini kullanmamızın ardındaki motivasyon, bu durumda uzamsal bilgiyi kullanan yöntemlerin performansının incelenmesidir.



Şekil 4.3 Botswana verisi için yapay renkli görüntü ve yer-gerçekliği görüntüsü.

Botswana verisi Okavango Deltası'nda yer alan Botswana üzerinden Hyperion sensörü kullanılarak alınmıştır. 0.4 - 2.5 μm aralığından alınmış 242 banttan oluşmaktadır, su bantları ve gürültülü bantlar atılmış ve 145 banda indirilmiştir. Görüntü radyans verisi olarak 1496×256 örnekten oluşmaktadır. Nispeten düşük uzamsal çözünürlüğe sahiptir (piksel başına 30 metre). Bu veride su, ormanlık alan, otlak, toprak alanları olmak üzere Tablo 4.4'te görüldüğü gibi 14 sınıftan toplamda 3248 örnek bulunmaktadır.

Tablo 4.4 Botswana veri kümesi etiketli örnek bilgileri

Sınıf Numarası	Sınıf İsimleri	Etiketli Örnek Sayısı
C1	Water	270
C2	Hippo grass	101
C3	Floodplain grasses1	251
C4	Floodplain grasses2	215
C5	Reeds1	269
C6	Riparian	269
C7	Firescar2	259
C8	Island interior	203
C9	Acacia woodlands	314
C10	Acacia shrublands	248
C11	Acacia grasslands	305
C12	Short mopane	181
C13	Mixed mopane	268
C14	Exposed soils	95
Toplam Etiketli Örnek Sayısı		3248


4.1.2. Müsilaj Veri Kümeleri

Tez kapsamında kullanılan müsilaj verileri Türkiye’de yer alan Marmara Denizi üzerinden PRISMA sensörü kullanılarak toplanmıştır. Bu veriler literatüre yeni sunulmuş müsilaj veri kümeleridir [87]. PRISMA, hiperspektral görüntüler sağlayan İtalyan uzay ajansının bir uydusudur [154, 155]. Uydu, yeryüzüne yaklaşık 600 km uzaklıkta yörüngede bulunmaktadır ve tekrarlama aralığı 29 gündür. Ortalama 12 nanometre (nm) spektral çözünürlüğe sahip olan bu uydu, 0.4 - 2.5 μm aralığından alınmış 239 bantta (SWIR ve VNIR bantlarında) 30m uzamsal çözünürlükte veriler sağlamaktadır. Uydu tarafından sağlanan spektral bantların dağılımı, Şekil 4.5’te siyah çubuklar olarak gösterilmektedir.


Marmara Denizi’nin doğusunu kaplayan 35TPF ve 35TPE bölgeleri üzerinden alınan veriler üzerinden deneyler yapılmıştır. İnceleme için seçilen bölge ve koordinatları Şekil 4.4(a)’da gösterilmektedir. Hiperspektral görüntülerde, yöntemlerin müsilaj tespiti performansını değerlendirmek için, Marmara Denizi üzerinden elde edilen Şekil 4.4(b) ve Şekil 4.4(c)’de verilen iki görüntü kullanılmıştır. Bu iki görüntü içerisinde müsilajın yoğun olarak bulunduğu (görüntüler içerisinde işaretlenmiş) bölgelerden alınmış kesitler deneyler



(a) Çalışma için seçilen Sentinel bölgeleri




(b) 35TPF içerisinde İstanbul müsilağ verisinin alındığı bölge



(c) 35TPE içerisinde Bursa müsilağ verisinin alındığı bölge


Şekil 4.4 Müsilağ verisi için kullanılan bölgeler

sırasında veri kümeleri olarak kullanılmıştır. İstanbul veri kümesi 19 Mayıs 2021 tarihinde 35TPF bölgesinden toplanmış görüntü içerisinde bir kesittir, Bursa veri kümesi ise 13 Mayıs 2021 tarihinde 35TPE bölgesinden toplanmış görüntü içerisinde alınan bir kesittir. Bu veri kümeleri deniz ve müsilağ olmak üzere 2 sınıftan oluşmaktadır. Müsilağ ve deniz sınıfları, [87] çalışması tarafından elle etiketlenmiştir. Veri kümelerine ait ayrıntılı bilgiler aşağıda verilmiştir.



Şekil 4.5 PRISMA uydularına ait spektral yanıt fonksiyonu. Görselde siyah çizgiler PRISMA uydusuna ait spektral yanıtları göstermektedir.

İstanbul Müsilaj Veri Kümesi: Deneylerde kullanılan müsilaj veri kümelerinden ilki, İstanbul Müsilaj veri kümesidir. PRISMA uydusu tarafından sağlanan veriden bazı bantlar atılarak 234 banda indirilmiştir. Ayrıca görüntüden alınan 350×490 'lık bir kesit üzerinde deneyler yapılmıştır. Kullanılan kesite ait yapay renkli görüntü ve yer-gerçekliği görüntüsü Şekil 4.6'da verilmiştir.




Şekil 4.6 İstanbul müsilaj verisi için yapay renkli görüntü ve yer-gerçekliği görüntüsü. Yer-gerçekliği görüntüsünde mavi renkli bölgeler denizi beyaz renkli bölgeler müsilajı göstermektedir.

Tablo 4.5 İstanbul veri kümesi etiketli örnek bilgileri

Sınıf Numarası	Sınıf İsimleri	Etiketli Örnek Sayısı
C1	Deniz	170930
C2	Müsilaj	570
Toplam Etiketli Örnek Sayısı		171500

Bu veri kümesinde deniz ve müsilağ olmak üzere 2 sınıf bulunmaktadır. Burada müsilağlı alanlar uzun ince köpükler şeklinde göze çarpmaktadır. Veri kümesi Tablo 4.5’te görüldüğü gibi 2 sınıfta toplamda 171500 örnekten oluşmaktadır.

Bursa Müsilağ Veri Kümesi: Deneylerde kullanılan bir diğer veri kümesi Bursa Müsilağ verisidir. PRISMA uydusu tarafından sağlanan veriden bazı bantlar atılarak 234 banda indirilmiştir. Ayrıca görüntüden alınan 421×571 ’lik bir kesit üzerinde deneyler yapılmıştır. Kullanılan kesite ait yapay renkli görüntü ve yer-gerçekliği görüntüsü Şekil 4.7’de verilmiştir. Bu veri kümesinde deniz ve müsilağ olmak üzere 2 sınıf bulunmaktadır. Burada müsilağlı alanlar uzun ince köpükler şeklinde göze çarpmaktadır. Veri kümesi Tablo 4.6’da görüldüğü gibi 2 sınıfta toplamda 223630 örnek bulunmaktadır.



Şekil 4.7 Bursa müsilağ verisi için yapay renkli görüntü ve yer-gerçekliği görüntüsü. Yer-gerçekliği görüntüsünde mavi renkli bölgeler denizi beyaz renkli bölgeler müsilağ, siyah renkli bölgeler etiketsiz verileri göstermektedir.

Tablo 4.6 Bursa veri kümesi etiketli örnek bilgileri


Sınıf Numarası	Sınıf İsimleri	Etiketli Örnek Sayısı
C1	Deniz	220019
C2	Müsilağ	3611
Toplam Etiketli Örnek Sayısı		223630

4.2. Sentetik Veriler ile Yapılan Deneyler Üzerinde Önerilen SSNSC Yaklaşımının Çalışma Mekanizmasının İncelenmesi

Bu bölümde önerdiğimiz SSNSC yaklaşımının çalışma mekanizması sentetik veriler üzerinden incelenmiştir. Bu kısımda yapılan deneylerde veri kümesinde üç sınıf bulunduğu varsayımı vardır. Bu sınıflara ait veriler Salinas veri kümesine ait iki sınıftan alınmış veriler ve Indian Pines veri kümesinden bir sınıfa ait alınmış verilerdir. Sınıflara ait 5'er veri, eğitim verisi olarak kullanılmıştır. Yine bu sınıflardan başka veriler seçilerek uzamsal bölgeler oluşturulmuş ve bu uzamsal bölgeler için SSNSC yaklaşımının sınıflandırma mekanizması incelenmiştir. Oluşturulan bu bölgeler test örneğinin komşuluğunda uzamsal bir pencere olarak düşünülebileceği gibi bir süperpiksel gibi de düşünülebilir. Bu bölümde yapılan deneyler için bahsedilen üç sınıfa ait renk kodları ve bu sınıflara ait eğitim verilerinin spektral bilgileri Şekil 4.8'de verilmiştir.


Bu üç sınıfa ait verilere ek olarak, deneyler sırasında gürültülü pikseller de uzamsal bölge içerisine yerleştirilmiştir. Gürültülü pikseller herhangi bir sınıfa ait eğitim verileri ile benzerlik göstermeyen pikseller olarak düşünülebilir. Gürültülü pikseller olarak ifade ettiğimiz veriler Botswana veri kümesinde bir sınıftan alınmıştır. Gürültülü pikseller bu bölümde gri renk kodu ile ifade edilmiştir. Deneyler sırasında her senaryoda uzamsal bölge içerisinde yer alan tüm piksellere ait spektral bilgiler Şekil 4.9, Şekil 4.10 ve Şekil 4.11'de verilmiştir. Burada gürültülü piksellere ait spektral bilgilerin eğitim verilerinden çok farklı olduğu görülebilir. Deneyler sırasında senaryolar ile yaratılan uzamsal bölgeler için referans doğru etiketimiz yoktur. Bu yüzden senaryolar için yorumlar etiket kestiriminin doğruluğundan bağımsız olarak yapılmaktadır.

Sentetik veriler ile yapılan deneylerde Şekil 4.9, Şekil 4.10 ve Şekil 4.11'de gösterildiği gibi farklı farklı senaryolar oluşturulmuştur. Oluşturulan ilk senaryolar Şekil 4.9'da yer almaktadır. Gürültülü piksellerin sınıflandırma performansına etkisinin incelenmesi açısından bu senaryolar oluşturulmuştur. Bu senaryolarda uzamsal bölge içerisinde gürültülü pikseller ve tek bir sınıfa ait örnekler bulunmaktadır. Her bir piksel ait spektraller Şekil 4.9(a),(b) ve (c)'de verilmiştir.




Şekil 4.8 Sentetik veriler ile yapılan deneylerde kullanılan 3 sınıf için eğitim verileri: Her bir sınıfta 5 tane eğitim verisi bulunmaktadır. Referans olması açısından eğitim verilerinin birbirleri ile olan kanonik korelasyon değerleri de verilmektedir. C1'e ait eğitim verileri ile C2'ye ait eğitim verileri arasındaki en büyük kanonik korelasyon değeri 0.9359, C1'e ait eğitim verileri ile C3'e ait eğitim verileri arasındaki en büyük kanonik korelasyon değeri 0.8961 ve C2'ye ait eğitim verileri ile C3'e ait eğitim verileri arasındaki en büyük kanonik korelasyon değeri 0.9363'tür.


Şekil 4.9(a)'da görüldüğü gibi ele alınan ilk uzamsal bölge homojendir ve C1 sınıfına ait örnekler içermektedir. Bu durumda uzamsal bölge içerisinde kalan pikseller ile sınıf bazında eğitim verileri arasındaki kanonik korelasyon değerleri ρ_1 , ρ_2 , ρ_3 Şekil 4.9(a)'da verilmiştir. ρ_1 değeri, ρ_2 ve ρ_3 değerlerinden yeterince büyüktür ve uzamsal bilgi ile elde edilen etiket C1'dir. Şekil 4.9(b)'de uzamsal bölge içerisine gürültülü pikseller eklenmiştir ve Şekil 4.9(c)'de gürültülü piksellerin sayısı artırılmıştır. Gürültülü pikseller artırılrsa bile ρ_1 değeri



(a) Senaryo 1



(b) Senaryo 2



(c) Senaryo 3


Şekil 4.9 Uzamsal bölge içerisinde yer alan gürültülü piksellerin sınıflandırma performansına etkisinin incelenmesi için sentetik veriler ile oluşturulan senaryolar

ile ρ_2 ve ρ_3 değerleri arasındaki fark büyük bir oranda değişmemektedir, hatta bu fark Şekil 4.9(c)'de daha da artmıştır. Bu üç senaryodan anlaşıldığı üzere önerilen SSNSC yaklaşımı uzamsal bölge içerisinde yer alan gürültülü piksellere karşı dayanıklıdır.


Şekil 4.10'da Senaryo 4 ve Senaryo 5'te uzamsal bölge içerisinde farklı farklı sınıflara ait örneklerin bulunduğu senaryolar oluşturulmuştur. Senaryo 4'te uzamsal bölge içerisinde iki adet C3 sınıfına ait piksel bulunuyorken yedi adet C1 sınıfına ait piksel bulunmaktadır. Korelasyon değerlerine bakıldığında bu senaryoda SSNSC yaklaşımı çoğunluk oylama gibi çalışmış ve en yüksek korelasyon değeri C1 sınıfında çıkmıştır. Senaryo 5'e baktığımızda uzamsal bölge içerisinde iki adet C3 sınıfına ait piksel, iki adet C2 sınıfına ait piksel, beş adet C1 sınıfına ait piksel bulunmaktadır. Bu senaryoda durum Senaryo 4'teki durumdan tamamen farklıdır. En çok sayıda piksel C1 sınıfına aitken, SSNSC yaklaşımı ile kestirilen etiket C2'dir. Buradan anlıyoruz ki SSNSC yaklaşımı bire-bir çoğunluk oylama gibi çalışmamaktadır.

Şekil 4.11'de Senaryo 6 ve Senaryo 7'de uzamsal bölge içerisinde piksellerin karışım oranları iyice artırılmış ve SSNSC yaklaşımının davranışı incelenmiştir. Senaryo 6'da her üç sınıftan da üçer piksel bulunmaktadır. Bu durumda SSNSC yaklaşımı ile kestirilen etiket C1 çıkmıştır. Senaryo 7'de ise C1 sınıfına ait tek bir örnek vardır. Burada bu tek örnek için C1 sınıfına ait eğitim örneklerinden bir tanesi koyulmuştur. C1 sınıfına ait tek bir örnek, diğer sınıflara ait dörder örnek olmasına rağmen SSNSC yaklaşımı ile kestirilen etiket C1 olmuştur. Bu deneylerden anlaşıldığı üzere SSNSC yaklaşımı ile etikete karar verme sürecinde uzamsal bilgi içerisindeki sınıfların sayısal olarak çoğunluğundan ziyade eğitim verileri ile olan benzerlikleri rol oynamaktadır. Elbette ki sayısal olarak çoğunlukta olmak o sınıfın seçilme ihtimalini artırsa da garanti etmemektedir.

Sentetik veriler üzerinde yapılan deneyler, önerilen yaklaşımın uzamsal bölge içerisindeki gürültülü piksellere dayanıklı olduğunu gösterse de uzamsal bölge içerisinde farklı sınıflardan pikseller olduğu durumda benzerliğe göre herhangi bir sınıfa karar verebilmektedir. Farklı sınıflara ait örneklerin olması bir ikiliğe neden olmaktadır. Komşuluk ilişkisine dayanarak varsayım yapılan bu tip yöntemlerde bu gibi yanlış sınıflandırılmalar




(a) Senaryo 4



(b) Senaryo 5

Şekil 4.10 Uzamsal bölge içerisinde farklı sınıflara ait piksellerin bulunduğu durumlarda SSNSC yaklaşımının davranışının analizi için sentetik veriler ile oluşturulan senaryolar

kaçınılmazdır. Burada asıl üzerinde durulması gereken, uzamsal bilgi olarak homojen bölgelerin elde edilmesidir. Bu nedenle pencere tabanlı WBNSC yönteminde kullanılan sabit uzamsal komşuluk sınıf sınırlarında yanlış sınıflandırmalara neden olabilmektedir. Pencere-den ziyade homojen süperpiksellerin elde edilmesi SSNSC yaklaşımının performansı için büyük önem taşımaktadır.



Şekil 4.11 Uzamsal bölge içerisinde farklı sınıflara ait piksellerin bulunduğu durumlarda SSNSC yaklaşımının davranışının analizi için sentetik veriler ile oluşturulan senaryolar

4.3. WBNSC Yöntemi için Yapılan Deneyler

Bu bölümde önerilen WBNSC algoritmasının etkinliği NSC [156], NRS [68], SaCRT [99], (LSRC) [157] gibi spektral tabanlı sınıflandırma yöntemlerinin yanı sıra JNSC [78], RJNSC [78], CCJSR [158], SVM -MV [159], SKCR) [160] ve derin öğrenme tabanlı bir yöntem olan RPNet [161] gibi spektral-uzamsal tabanlı yöntemler ile karşılaştırılmıştır.

Deneylerin ilk kısmında sınıf başına rastgele seçilen 40 eğitim örneği ile deneyler yapılmıştır ve kalan örnekler test örnekleri olarak kullanılmıştır. Buna ek olarak sınırlı eğitim örneği olduğu durumda yöntemlerin performansını değerlendirmek amacıyla daha az eğitim örneği ile de deneyler yapılmıştır. Sınıf başına eğitim örneği sayısı 5, 10, 15, 20, 25, 30, 35, 40 için de sonuçlar alınmıştır. Adil bir karşılaştırma olması açısından karşılaştırma yaptığımız spektral-uzamsal yöntemler ve önerdiğimiz yöntem kullanılırken test örneğinin uzamsal komşuluğunda yer alan eğitim örnekleri sınıflandırma sırasında uzamsal bilgi olarak hesaba katılmamıştır. Sınıflandırma performanslarını niceliksel olarak karşılaştırmak için deneyler sırasında performans ölçütleri olarak ortalama genel doğruluk (OA), ortalama doğruluk (AA) ve ortalama kappa katsayısı (κ) kullanılmıştır.

4.3.1. Parametre Düzenleme

Önerilen WBNSC yönteminde, sınıflandırma performansını artırmak için ayarlanması gereken tek parametre uzamsal pencere boyutudur. Pencere boyutunun sınıflandırma performansı üzerindeki etkisini analiz etmek amacıyla tüm veri kümeleri için farklı uzamsal pencere boyutları 1×1 , 3×3 , 5×5 , 7×7 ve 9×9 ile önerilen yöntem test edilmiştir. Tüm bu değerler için sınıf başına rastgele seçilmiş 40 eğitim örneği kullanılarak 10 koşu için sonuçlar alınmıştır. Değişen pencere boyutları için önerilen WBNSC yöntemine ait ortalama sınıflandırma doğrulukları Tablo 4.7’de verilmiştir. Tabloda ilk satırda, $T = 1$, herhangi bir uzamsal bilgi kullanılmadan sadece spektral bilgi kullanılarak sınıflandırmanın gerçekleştirildiği durumu göstermektedir. Önerilen yöntemde parametrenin $T = 1$ seçildiği durum, mesafe metriği farklı olması dışında, NSC yöntemine eşdeğerdir. Önerilen yöntemde mesafe metriği olarak korelasyon kullanılıyorken, NSC yönteminde ise Öklid mesafesi kullanılmaktadır. Farklı veri kümeleri için Tablo 4.7’de verilen $T = 1$ sınıflandırma doğruluğu, Tablo 4.8, Tablo 4.9 ve Tablo 4.10’da verilen NSC yönteminin doğruluğu ile tutarlıdır. Tabloda $T = 1$ ’in altındaki satırlarda farklı pencere boyutları için alınan sonuçlar yer almaktadır. En iyi sonuçlar koyu renkli olacak şekilde vurgulanmıştır. 11×11 gibi daha büyük pencere boyutları için de sonuçlar alınmıştır. Fakat, daha büyük pencere boyutları için sonuçların daha düşük olması nedeniyle sonuçların verilmesine ihtiyaç duyulmamıştır.


Tablo 4.7 Önerilen WBNSC yönteminin farklı pencere boyutları için sınıflandırma performansları

Uzamsal Pencere Boyutu	Salinas	Indian Pines	Botswana
1×1	87.33	61.55	90.83
3×3	92.81	80.33	98.07
5×5	94.32	86.22	99.02
7×7	94.72	87.12	98.59
9×9	94.44	86.00	96.38


Sonuçları görsel olarak incelemek amacıyla farklı pencere boyutları için sınıflandırma haritaları (10 koşudan biri) da Şekil 4.12’de verilmiştir. Bu nedenle Şekil 4.12’deki farklı pencere boyutları için verilen doğruluk değerleri Tablo 4.7’dekinden farklıdır. Şekil 4.12’de dikkatimizi çeken ilk şey, sadece spektral bilginin kullanılması ($T = 1 \times 1$) durumunda çok sayıda yanlış sınıflandırılmış tekli piksellerin olduğu olmuştur. Uzamsal pencere boyutu arttıkça ise bu yanlış sınıflandırılmış tekli piksel sayısı azalmaktadır. Bu nedenle, $T \geq 1$ için tüm pencere boyutu ayarlarının performansı, Tablo 4.7’de gösterildiği gibi $T = 1$ olduğu duruma kıyasla daha yüksektir. Diğer yandan, Şekil 4.12’de görüldüğü çok büyük pencere boyutları sınıf sınırlarında yanlış sınıflandırmalara neden olmaktadır.

Pencere boyutu parametresinin etkisini daha iyi analiz etmek için, Indian Pines veri kümesinin sınıflandırma haritasından örnek bir bölge seçilmiş ve farklı pencere boyutları için yakınlştırılmış sınıflandırma haritaları Şekil 4.13’te verilmiştir. Örnek olarak verilen bölgede Corn-mintill (C2), Grass-pasture (C3) ve Soybean-clean (C7) olmak üzere 3 sınıf bulunmaktadır. Şekil 4.13 incelendiğinde pencere boyutu arttıkça, sınıf sınırlarında yanlış sınıflandırılmış piksellerin olduğu gözlemlenmiştir. Fakat bu yanlış sınıflandırmalar sınıfların tüm sınırlarında olmamaktadır. Sınıf sınırlarındaki test pikselleri etrafında yer alan uzamsal pencereler; arkaplan (etiketlenmemiş örnekler), gürültü ve diğer sınıflardan gelen pikseller gibi homojen olmayan pikselleri içerebilmektedir. Önerilen WBNSC yöntemi bu tarz durumlara karşı dayanıklıdır.

Şekil 4.13 incelendiğinde özellikle diğer sınıf bölgelerine yakın olan sınırlarda yanlış sınıflandırılmış pikseller bulunduğu gözlemlenmiştir. Diğer sınırlarda yanlış sınıflandırılmış



Şekil 4.12 Uzamsal pencere boyutunun önerilen yöntemimiz üzerindeki etkisinin analizi. Sırasıyla (a) Salinas (b) Indian Pine ve (c) Botswana veri kümeleri için yer-gerçekliği görüntüleri ve farklı uzamsal pencere boyutları 1, 3, 5, 7, 9 için sınıflandırma haritaları.



Şekil 4.13 Indian Pines veri sahnesi içerisinde örnek bir bölge üzerinden uzamsal pencere boyutunun önerilen yöntemimiz üzerindeki etkisinin analizi.

pikseller yoktur. Örneğin, C2, C3 ve C7 sınıflarının başka sınıfa yakın olmayan kenarlarında bu tarz yanlış sınıflandırılmış pikseller bulunmamaktadır. Bu da gösteriyor ki önerilen WBNSC yöntemi, pencere içerisinde bulunan gürültü ve arkaplan piksellerine karşı dayanıklıdır. Fakat, pencere içerisinde diğer sınıflara ait piksellerin yer alması önerilen yöntemin performansını olumsuz yönde etkilemektedir. Bu nedenle, büyük pencereler, özellikle birbirlerine yakın olan sınıfların sınırlarında yanlış sınıflandırılmış piksellere neden olmaktadır. Bu bahsedilen yanlış sınıflandırılmış piksellere örnekler, Şekil 4.13'te C2 sınıfının diğer sınıflara yakın olan kenarlarında göze çarpmaktadır. Bu, önerilen WBNSC yönteminin dezavantajlarından bir tanesidir. Bu dezavantajı ortadan kaldırmak için uzamsal pencereler yerine süperpikseller (homojen piksellerin bulunduğu kompakt bölgeler) kullanan süperpiksel tabanlı yöntemler önerilmiştir. Yukarıda bahsedilen nedenlerden dolayı Tablo 4.7'de görüldüğü gibi en büyük pencere boyutu, en iyi performansın elde edilmesi anlamına gelmemektedir. Tablo 4.7'de görüldüğü gibi, Indian Pines ve Salinas veri kümeleri için en uygun pencere boyutu 7'dir ve Botsvana için olanı 5'tir. Deneylerde bu ayarlamalar kullanılmaktadır.

Önerilen WBNSC yönteminin literatürde bulunan ve uzamsal bilgiyi kullanan diğer yöntemlere göre avantajlarından biri, yalnızca pencere boyutu (T) parametresinin ayarlanması gerektiğidir ve bu pencere boyutu parametresi sınıflandırılma yapılan alanın büyük homojen alanlar (kırsal bölge) içerip içermediği gibi bazı basit ön bilgiler sayesinde kolaylıkla ayarlanabilir. Örneğin, bölge Indian Pines ve Salinas veri kümeleri gibi kırsal ise, bölgenin geniş homojen bölgeler içermesi beklenir ve bu nedenle, en uygun pencere boyutunun büyük olması beklenir (örneğin, 7×7). Aksine, eğer kentsel bir bölgeden alınan karmaşık ve küçük

bölgeler içeren bir sahne ise, en uygun pencere boyutu nispeten daha küçük olmalıdır (örneğin 3×3).

Deneyler sırasında karşılaştırma için kullanılan tüm yöntemlere ait hiper-parametreler için de optimum değerler belirlenmiştir. Çoğunluk oylamalı destek vektör makinesi yönteminde ilk olarak piksel bazında sınıflandırma gerçekleştirilmektedir. Nihai sınıflandırma sonucu, uzamsal pencerede içerisinde yer alan piksellerin etiketleri dikkate alınarak çoğunluk oylama ile elde edilmektedir. Radial basis function (RBF) kernel [162] ile SVM için düzenleme (regularization) parametresini ve çekirdek (kernel) parametresini belirlemek için beş katlı çapraz doğrulamalı ızgara aramasından (grid search with five-fold cross-validation) yararlanılmıştır. Bu yöntem için Salinas, Indian Pines ve Botswana veri kümeleri için en uygun pencere boyutları sırasıyla 11, 9 ve 3'tür.

CCJSR yönteminde Salinas ve Indian Pines veri kümeleri için en uygun pencere boyutu 7 iken Botswana için 3'tür ve seyreklik düzeylerinin en uygun değerleri Salinas ve Botswana için 3, Indian Pines için 2'dir. RJNSC için, optimal düzenleme parametresinin değerleri Salinas ve Botswana için 10^{-2} ve Indian Pines için 10 olarak belirlenmiştir. JNSC ve RJNSC yöntemlerinde, tüm veri kümeleri için en uygun pencere boyutu 3 olarak belirlenmiştir. RJNSC'de, tüm veri kümeleri için yineleme sayısı 50 olarak ayarlanmıştır. SKCR için süperpiksel sayısı parametresi, en yakın komşu oranı, ödünleşim (tradeoff) parametresi sırasıyla 200, 0.5 ve 0.07 olarak ayarlanmıştır [160]. RpNet yöntemi parametreleri; yama sayısı, yama boyutu, temel bileşenlerin sayısı ve ağırlık derinliği [161]'te verildiği gibi sırasıyla 20, 21, 3 ve 5 olarak ayarlanmıştır.


NRS yönteminde parametre ayarlamak için mevcut eğitim örneklerine dayalı bir çapraz doğrulama (cross validation) stratejisi kullanılmıştır. LSRC için, seyreklik parametresi ve en yakın komşu örnek sayısının optimal değerleri sırasıyla 6 ve 20 olarak ayarlanmıştır [157]. SaCRT yöntemi için en uygun düzenleme parametreleri [99]'de verildiği gibi Indian Pine veri kümesi için 5, $1e^{-3}$, $1e^{-3}$, Salinas veri kümesi için 5, $1e^{-4}$, $1e^{-3}$ ve Botswana veri kümesi için 10, $1e^{-4}$, $1e^{-3}$ şeklinde ayarlanmıştır.

4.3.2. Salinas Veri Kümesi ile Yapılan Deneyler

Salinas veri kümesi için sınıf başına 40 eğitim örneği için elde edilen farklı yöntemlerin sınıflandırma haritaları (10 koşudan biri) Şekil 4.14'te verilmiştir ve bu veri kümesi için yöntemlerin her bir sınıf için ayrıntılı sınıflandırma performansları Tablo 4.8'de verilmiştir. İlk olarak görsel sonuçları analiz ettiğimizde Şekil 4.14'te görüldüğü üzere spektral tabanlı yöntemlerin sonuçlarını gösteren sınıflandırma haritalarında birçok yanlış sınıflandırılmış tekli pikseller bulunmaktadır. Spektral-uzamsal tabanlı sınıflandırma yöntemlerinde uzamsal bilgi kullanımının bu tarz yanlış sınıflandırılmış tekli piksellerden kurtulmak için etkili olduğu görülmektedir. Bu sayede, spektral-uzamsal tabanlı sınıflandırma yöntemleri ile elde edilen sonuçlar daha pürüzsüzdür ve hemen hemen tüm spektral-uzamsal sınıflandırma yöntemlerinin performansının spektral tabanlı yöntemlerden daha iyi olduğu Şekil 4.14 ve Tablo 4.8'de görülmektedir. Bununla birlikte, eğer bir spektral-uzamsal tabanlı sınıflandırma yöntemi gürültülü piksellere karşı dayanıklı değilse, yanlış sınıflandırılmış tekli pikseller yerini yanlış sınıflandırılmış bölgelere bırakmaktadır. Yani bu gürültülü pikseller etrafındaki piksellerin de yanlış sınıflandırılmasına neden olmaktadır. Şekil 4.14 incelendiğinde yanlış sınıflandırılmış bölgeler özellikle JSRC ve CCJSR yöntemlerine ait sınıflandırma haritalarında belirgindir.

Diğer yandan, uzamsal bilgilerin kullanılması, özellikle JNSC, RJNSC ve RPNet için olmak üzere hemen hemen tüm spektral-uzamsal tabanlı yöntemler için sınıf sınırlarında yanlış sınıflandırmalara neden olmaktadır. Şekil 4.14'e bakıldığında bahsedilen problemlerin önerilen WBNSC yönteminde daha az görüldüğü gözlemlenmiştir. Bu da önerdiğimiz WBNSC yönteminin gürültülü piksellere ve arkaplan piksellerine karşı daha dayanıklı olduğunu bize göstermektedir. SKCR yöntemi de uzamsal pencere yerine süperpikseller kullandığı için bu tür sorunlarla daha iyi başa çıkmaktadır.

Tablo 4.8 incelendiğinde sınıf bazında en iyi olan yöntemler SKCR, SVM-MV ve önerilen WBNSC yöntemidir. C1, C2, C3, C4, C6, C7, C9, C16 sınıfları için spektral tabanlı yöntemler ve spektral-uzamsal tabanlı yöntemler arasında belirgin bir performans farkı yoktur. Uzamsal bilginin kullanılması C10, C11, C12, C15 gibi sınıflarda belirgin iyileştirmeler



Şekil 4.14 Salinas verisi için WBNSC yöntemi ve karşılaştırılan diğer yöntemler ile elde edilen sınıflandırma haritaları. Sınıf başına 40 örnek eğitim verisi olarak kullanılmış, geriye kalan örnekler test verisi olarak kullanılmıştır.

Tablo 4.8 Salinas verisi için önerilen WBNSC yöntemi ve karşılaştırılan diğer yöntemlerin sınıflandırma doğrulukları (%)

Sınıf	NSC	NRS	SaCRT	LSRC	CCJSR	JNSC	RJNSC	SVM-MV	RpNet	SKCR	WBNSC
C1	99.60	99.59	99.70	99.87	100	99.56	99.55	100	98.18	100	<u>99.95</u>
C2	99.08	98.64	99.57	99.03	99.27	99.68	99.86	100	94.07	100	<u>99.99</u>
C3	98.44	99.43	97.00	97.11	<u>99.54</u>	99.45	99.52	99.04	99.03	100	100
C4	99.29	99.40	98.31	97.45	91.71	99.00	99.03	99.79	98.42	<u>99.71</u>	96.43
C5	92.28	96.16	96.64	97.24	97.19	93.00	94.92	98.70	98.67	99.02	<u>98.75</u>
C6	99.42	99.47	<u>99.97</u>	99.24	99.56	97.48	97.60	100	99.60	99.84	99.66
C7	99.45	99.40	99.74	99.23	99.61	97.06	97.11	99.97	97.08	99.90	<u>99.93</u>
C8	72.75	75.74	79.59	71.62	70.57	86.40	82.69	82.00	82.60	<u>91.71</u>	92.88
C9	96.47	98.23	99.24	98.91	99.34	96.03	96.32	<u>99.98</u>	99.65	99.99	99.99
C10	96.91	95.23	93.41	92.83	95.37	98.06	97.41	96.21	98.70	<u>98.07</u>	97.56
C11	98.40	97.13	93.55	96.68	99.69	99.05	99.19	<u>99.95</u>	99.26	99.96	99.63
C12	98.66	99.95	94.89	97.33	99.59	99.91	74.89	100	98.03	<u>99.16</u>	98.42
C13	97.30	98.02	96.73	94.94	95.66	93.71	73.71	99.24	<u>98.89</u>	92.57	96.67
C14	97.51	96.49	92.12	93.66	98.04	96.74	72.74	99.48	99.22	95.41	<u>99.05</u>
C15	60.18	66.98	63.52	68.39	75.17	63.79	75.32	80.91	<u>88.41</u>	94.78	75.59
C16	98.90	98.40	99.19	97.02	97.73	98.70	98.64	<u>99.50</u>	99.35	99.60	99.37
OA(%)	87.48	89.33	89.17	88.28	89.43	90.64	89.86	93.26	93.68	97.11	<u>94.72</u>
AA(%)	94.04	94.89	93.95	93.79	94.88	94.85	91.16	97.17	96.82	98.11	<u>97.12</u>
κ (%)	86.06	88.12	87.96	86.96	88.25	89.55	88.70	92.50	92.97	96.78	<u>94.10</u>

sağlamıştır. Birçok yöntem C8 ve C15 sınıflarında zorlanmıştır ve doğrulukları çok düşüktür. Şekil 4.14'te yer alan sınıflandırma haritalarına bakıldığında da bu iki sınıfın birbirine karıştırıldığı görülmektedir. Bu sınıflardaki performansların düşüklüğünün nedeni de sınıfların spektral imzalarının birbirine olan benzerliğidir. Genel doğrulukta (OA), yöntemlerin C8 ve C15 sınıflarındaki performansları belirleyici olmaktadır. Tablo incelendiğinde sırasıyla SVM-MV ve RpNet yöntemleri bu sınıfları doğru sınıflandırmakta zorluk çekmektedir. WBNSC yöntemi ise C15 sınıfını doğru sınıflandırmakta zorlansa da C8 sınıfı için en yüksek doğruluğa sahiptir.


Bölüm 4.2. ve 4.3.1.'de belirtildiği gibi, pencere içerisinde diğer sınıflara ait piksellerin yer alması önerilen yöntemin performansını olumsuz etkilemektedir. Bu nedenle, önerilen WBNSC yönteminin performansı C12, C13 gibi sınıflarda SVM-MV ve RpNet'ten daha düşüktür. Öte yandan, önerilen WBNSC yöntemi, uzamsal pencerede gürültü ve arkaplan piksellerinin olmasına karşı dayanıklı olması nedeniyle, diğer sınıflara yakın olmayan -izole olan- C3 ve C9 gibi sınıflarda en iyi performansı göstermektedir.

SKCR yönteminin WBNSC yöntemine göre iki avantajı vardır. Bunlardan ilki, uzamsal bilgi olarak süperpiksellerden yararlanmasıdır. Bu sayede WBNSC yönteminde sınıf sınırlarında karşılaşılan yanlış sınıflandırılmış örnekler bu yöntemde daha azdır. İkinci olarak, SKCR yöntemi içerisinde çekirdek (kernel) kullanılması veri kümesinin barındırdığı doğrusal olmayan özelliklerin yakalanabilmesini sağlamaktadır. Bu nedenlerden dolayı, SKCR yöntemi genel doğrulukta en iyi performansa sahipken, önerilen WBNSC yöntemi ise en iyi doğruluğa sahip ikinci yöntemdir. Önerilen WBNSC yöntemi, pencere-tabanlı yöntemler arasında en iyi performansa sahip yöntemdir. Önerilen WBNSC yönteminin genel doğruluğu sırasıyla RpNet, SVM-MV, JNSC ve RJNSC yöntemlerinden yaklaşık olarak 1.04%, 1.45%, 4% ve 4.85% daha yüksektir. Ayrıca ilerleyen bölümlerde daha az eğitim örneği ile yapılan deneyler de paylaşılmıştır ve önerilen yöntemimizin sınırlı eğitim verisi olması durumunda diğer yöntemlere göre daha iyi performans gösterdiği gözlemlenmiştir.

4.3.3. Indian Pines Verisi ile Yapılan Deneyler

Indian Pines veri kümesi için farklı yöntemlerin ayrıntılı sınıflandırma performansları ve bunlara karşılık gelen sınıflandırma haritaları sırasıyla Tablo 4.9 ve Şekil 4.15'te verilmiştir. Şekil 4.15 incelendiğinde RpNet, SKCR ve önerdiğimiz WBNSC yöntemlerine ait sınıflandırma haritaları diğer yöntemlere göre daha pürüzsüz bölgeler içermektedir. Bu yöntemler uzamsal bilgilerden daha etkili yararlanmaktadır ve gürültülü piksellere ve sınıflar arası benzerliğe karşı dayanıklıdır.

Daha önce bahsedildiği gibi, önerdiğimiz yöntem uzamsal pencere içerisinde gürültülü piksellerin ve arka plan piksellerinin varlığına karşı dayanıklıdır. Bu sayede WBNSC, diğer sınıflardan izole olan C4, C7 ve C6 gibi sınıflarda en iyi performansı göstermektedir. Diğer yandan, hemen hemen tüm diğer sınıflara ait bölgeler birbirlerine uzamsal olarak çok yakındır. Bu yakınlık önerilen yöntemimizin performansını olumsuz yönde etkilemektedir. Bu nedenle, WBNSC'nin genel doğruluğu SKCR ve RpNet yöntemlerinden daha düşüktür. Fakat, önerilen yöntem RpNet ve SKCR dışındaki diğer yöntemlere göre bariz üstün bir performansa sahiptir. WBNSC'nin genel doğruluğu, SVM-MV, CCJSR, JSRC



Şekil 4.15 Indian Pines verisi için WBNSC yöntemi ve karşılaştırılan diğer yöntemler ile elde edilen sınıflandırma haritaları. Sınıf başına 40 örnek eğitim verisi olarak kullanılmış, geriye kalan örnekler test verisi olarak kullanılmıştır.

yöntemlerinden sırasıyla yaklaşık 3%, 7%, 7.1% daha yüksektir ve diğer yöntemlerde bu fark daha da yüksektir.

Sınıf içi değişkenlik, sınıflar arası benzerlikler ve düşük uzamsal çözünürlük, Indian Pines veri kümesini, Salinas'a kıyasla daha zorlu bir veri kümesi haline getirmektedir. Bu nedenle, Şekil 4.15'te görüldüğü gibi Indian Pines veri kümesi için spektral yöntemlerle elde edilen sınıflandırma haritaları Salinas veri kümesine göre çok daha fazla yanlış sınıflandırılmış tekli piksel içermektedir. Ayrıca Tablo 4.9'a bakıldığında tüm yöntemlere ait sınıflandırma başarımlarında Tablo 4.8'e göre genel bir düşüş görülmektedir. Buna ek olarak sınıflar da birbirlerine çok yakındır ve bu da önerilen WBNSC yönteminin performansını uzamsal bilgidan yararlanırken pencere kullanması nedeniyle olumsuz yönde etkilemektedir.

Tablo 4.9 Indian Pines verisi için önerilen WBNSC yöntemi ve karşılaştırılan diğer yöntemlerin sınıflandırma doğrulukları (%)


Sınıf	NSC	NRS	SaCRT	LSRC	CCJSR	JNSC	RJNSC	SVM-MV	RPNNet	SKCR	WBNSC
C1	48.21	50.10	66.17	59.37	67.50	57.48	60.45	75.28	88.26	<u>80.62</u>	79.18
C2	48.21	52.72	42.90	66.62	76.79	44.36	58.64	79.34	93.49	87.11	<u>91.63</u>
C3	83.36	87.40	85.12	90.99	92.75	79.84	89.32	<u>94.40</u>	96.52	94.06	91.67
C4	98.72	99.45	98.82	99.40	99.65	97.51	97.73	99.54	99.82	<u>99.88</u>	99.90
C5	61.96	64.35	55.99	73.37	86.59	67.17	80.47	89.90	90.88	89.59	<u>90.28</u>
C6	49.84	55.58	75.64	57.56	71.74	49.18	65.03	74.56	83.02	83.66	<u>76.96</u>
C7	49.96	55.58	45.16	66.25	75.60	50.48	70.74	93.11	<u>96.89</u>	92.76	97.81
C8	97.64	97.20	97.64	96.55	98.71	98.07	96.91	98.50	95.69	<u>99.28</u>	99.77
OA(%)	62.38	65.67	68.47	71.02	80.13	63.82	73.62	84.14	90.28	<u>88.54</u>	87.12
AA(%)	67.24	70.30	70.93	76.27	83.67	68.01	77.41	88.08	93.07	90.87	<u>90.90</u>
κ (%)	55.48	59.29	62.89	65.70	76.30	57.30	68.62	81.19	88.40	<u>86.26</u>	84.67

Ayrıca önerdiğimiz yöntem doğrusal bir sınıflandırıcıdır. Bu tarz zorlu veri kümelerinde önerdiğimiz WBNSC yöntemi gibi basit, ilkel yöntemler ile iyi sonuçlar almak daha zordur. RPNNet yöntemi ise çok katmanlı olması, lineer olmayan aktivasyon fonksiyonu içermesi sebebiyle yeterli sayıda eğitim verisi olduğu durumda bu tip zorlu veri kümelerinde daha iyi performans göstermektedir. Benzer şekilde Bölüm 4.3.2.'de de belirtildiği gibi SKCR yönteminde süperpiksel ve çekirdek kullanılması Salinas ve Indian Pines veri kümelerinde SKCR yönteminin, önerdiğimiz WBNSC yöntemine kıyasla daha iyi sonuçlar elde etmesini sağlamıştır. Bu da bizi süperpiksel kullanma ve süperpiksel tabanlı yöntemler geliştirme yönünde motive etmiştir.

4.3.4. Botswana Verisi ile Yapılan Deneyler

Botswana veri kümesi için farklı yöntemlerin ayrıntılı sınıflandırma performansları ve bunlara karşılık gelen sınıflandırma haritaları sırasıyla Tablo 4.10 ve Şekil 4.16'da verilmiştir. Bu veri kümesini Şekil 4.16 üzerinden görsel olarak analiz etmek zordur. Ancak Tablo 4.10 incelendiğinde Botswana veri kümesi içerisinde yer alan sınıfların birbirlerinden ayırt edilebilir olduğu tüm yöntemlerin performanslarının diğer iki veri kümesine göre daha yüksek olmasından anlaşılmaktadır.

Botswana veri kümesinde sınıflar küçük bölgelere sahiptir, bu yüzden test piksellerinin çoğu sınırlardadır ve test örnekleri için dikkate alınan uzamsal pencereler tutarsız, çoğunlukla



Şekil 4.16 Botswana verisi için WBNSC yöntemi ve karşılaştırılan diğer yöntemler ile elde edilen sınıflandırma haritaları. Sınıf başına 40 örnek eğitim verisi olarak kullanılmış, geriye kalan örnekler test verisi olarak kullanılmıştır.

etiketlenmemiş arka plan piksellerinden oluşmaktadır. Bazı spektral-uzamsal yöntemlerin performansı uzamsal pencereler içerisinde yer alan bu tür tutarsız piksellere karşı dayanıklı değildir. Bu nedenle, Tablo 4.10'da görüldüğü üzere spektral tabanlı yöntemlerin bazıları


Tablo 4.10 Botswana verisi için önerilen WBNSC yöntemi ve karşılaştırılan diğer yöntemlerin sınıflandırma doğrulukları (%)

Sınıf	NSC	NRS	SaCRT	LSRC	CCJSR	JNSC	RJNSC	SVM-MV	RPNet	SKCR	WBNSC
C1	99.69	100	<u>99.78</u>	100.00	100	99.21	99.17	100	98.74	99.52	99.26
C2	99.17	99.50	96.16	<u>99.83</u>	94.53	100	100	100	100	94.91	99.18
C3	96.91	98.86	99.62	99.62	99.86	99.85	<u>99.90</u>	100	99.19	100	99.71
C4	91.31	98.05	95.81	99.08	91.48	96.97	97.25	100	98.80	97.31	<u>99.60</u>
C5	85.89	88.82	90.19	85.32	86.63	97.07	96.68	83.13	<u>95.98</u>	93.97	97.72
C6	79.30	82.40	83.67	77.94	81.55	88.90	90.39	96.88	98.30	<u>97.81</u>	94.89
C7	98.99	98.49	99.76	99.04	<u>99.95</u>	99.81	99.81	99.88	100	99.13	100
C8	95.95	98.15	97.28	98.28	96.91	<u>99.93</u>	100	99.92	99.51	98.95	100
C9	83.10	90.54	94.27	91.64	89.27	95.18	95.36	97.71	<u>99.12</u>	99.59	98.86
C10	87.88	94.66	92.65	94.27	89.69	99.47	<u>99.56</u>	100	100	96.58	100
C11	94.30	93.58	95.79	96.75	98.00	99.50	<u>99.62</u>	96.08	98.72	95.77	99.88
C12	89.21	96.45	85.27	95.17	88.37	96.73	97.23	98.04	98.65	<u>99.00</u>	99.21
C13	88.94	89.78	92.60	92.36	88.56	98.99	99.07	100	98.33	95.74	<u>99.69</u>
C14	99.81	100	93.63	100.00	98.92	99.63	99.63	87.04	<u>99.82</u>	96.72	98.54
OA(%)	91.12	94.02	93.98	94.09	92.75	97.66	97.85	97.29	<u>98.80</u>	97.63	99.02
AA(%)	92.18	94.95	93.46	94.96	93.12	97.95	98.12	97.05	<u>98.94</u>	97.50	99.04
κ (%)	90.36	93.51	94.06	93.58	92.12	97.46	97.66	97.06	<u>98.70</u>	97.42	98.93

(CCJSR gibi), spektral-uzamsal yöntemlerin bazılarında daha yüksek doğruluklara sahiptir. Bölüm 4.2. ve Bölüm 4.3.1.'de belirtildiği gibi, önerilen yöntem WBNSC, test pikseli etrafındaki uzamsal pencerelerde gürültülü ve arkaplan piksellerinin varlığına karşı daha dayanıklıdır. Bu nedenle, WBNSC sınıfların çoğunda en iyi performansı göstermektedir. Önerdiğimiz WBNSC yöntemi en yüksek genel doğruluğa sahiptir ve sırasıyla RPNet, RJNSC, JNSC, SKCR, SVM-MV yöntemlerinden yaklaşık 0.22%, 1.17%, 1.36%, 1.39%, 1.7% daha yüksektir. Spektral tabanlı yöntemlerden de yaklaşık 4-5% yüksek performansa sahiptir.

4.3.5. Eğitim Örneği Sayısının Yöntemlerin Sınıflandırma Performansına Etkisi

Ağırlıklı olarak sınırlı eğitim örnekleriyle sınıflandırmaya odaklandığımız için bu bölümde küçük ölçekli eğitim örneklerinin yöntemlerin performansına etkisini analiz etmek için deneyler tasarlanmıştır. Bu kısımda, WBNSC'nin performansı sınıf başına farklı sayıda eğitim örnekleri (5, 10, 15, 20, 25, 30, 35, 40) için diğer yöntemlerle karşılaştırılmıştır. Salinas, Indian Pines ve Botswana veri kümelerine ait sınıf başına farklı sayıda eğitim örnekleri için yöntemlerin sınıflandırma performansları (OA) Şekil 4.17'de verilmiştir.



Şekil 4.17 Yöntemlerin (a) Salinas, (b) Indian Pines ve (c) Botswana veri kümeleri üzerinde değişen sınıf başına eğitim örneği sayıları için sınıflandırma performansları

Sonuçlar 10 farklı koşu için alınmış ve ortalamaları Şekil 4.17’de verilmiştir. Şekil 4.17’yi incelediğimizde, Botswana veri kümesinde eğitim örneklerinin sayısından bağımsız olarak tüm durumlarda önerilen WBNSC yöntemi ile en iyi sınıflandırma performanslarının elde edildiği gözlemlenmektedir. Keza, sınıf başına eğitim örneği sayısının 15’ten az olduğu durumda, önerilen WBNSC algoritması, üç veri kümesinde de diğer tüm algoritmalarından önemli ölçüde daha iyi performans göstermektedir. HSG işleme alanında etiketli verilere erişimin zor ve maliyetli olduğu göz önüne alındığında, önerilen WBNSC yönteminin sınırlı eğitim verisi sayısı ile elde ettiği bu başarı oldukça kıymetlidir. Sınıf başına eğitim verisi

sayısı 20 ve üzeri olduğunda, SKCR yöntemi Indian Pines ve Salinas veri kümelerinde önerdiğimiz WBNSC yöntemine göre daha iyi performans göstermektedir. Benzer şekilde, RpNet yöntemi de sınıf başına eğitim verisi sayısı 20 ve üzeri olduğunda, Indian Pines veri kümesi için performansı önerdiğimiz WBNSC yönteminin üzerine çıkmaktadır. Derin öğrenme yöntemlerinin doğru bir genelleme yeteneğine sahip olması için eğitim aşamasında yeterli sayıda etiketli örneğe ihtiyaç duyulmaktadır. Bu yüzden, RpNet'in performansı sınırlı sayıda eğitim örneği olduğu durumlarda yetersizdir. Öte yandan, eğitim örneklerinin sayısındaki artışla performansı artmaktadır.

4.3.6. Yöntemlerin Hesaplama Karmaşıklığının Analizi

Bu bölümdeki deneylerde yöntemlerin hesaplama karmaşıklıkları analiz edilmiştir. Deneyler, özellikleri 64 GB RAM ve 2,40 GHz ile Intel(R) Xeon(R) 3,2 GHz olan bir bilgisayar üzerinde ve MATLAB kullanılarak yapılmıştır. Önceki bölümde 40 eğitim verisi ile yapılan deneylerde Bölüm 4.3.2., Bölüm 4.3.3. ve Bölüm 4.3.4.'te kullanılan veriler üzerinden süre ölçümleri alınmıştır.

Salinas, Indian Pines, Botswana veri kümeleri için yöntemlerin ortalama yürütme süreleri Tablo 4.11'de verilmiştir. Verilerin boyutu, algoritmaların karmaşıklığı, spektral-uzamsal tabanlı yöntemlerde kullanılan pencere boyutu parametresi gibi faktörler yürütme süresini etkilemektedir. Tablo 4.1 incelendiğinde üç veri kümesi arasında etiketli örnek sayısı en yüksek olan veri kümesi Salinas veri kümesidir. Ayrıca, spektral-uzamsal tabanlı yöntemlerin optimal pencere boyutu parametresinin değeri, Bölüm 4.3.1.'de de belirtildiği gibi Salinas veri kümesinde diğer kümelerine göre daha büyüktür. Ek olarak Tablo 4.1'de görüldüğü üzere en yüksek bant sayısı ve sınıf sayısı da bu veri kümesine aittir. Botswana veri kümesinde ise Salinas verisi için geçerli olan durumların tam tersi geçerlidir. Bu nedenle, Salinas veri kümesi için yürütme süreleri tüm yöntemler için genellikle en yüksekken, Botswana veri kümesi için yürütme süreleri tüm yöntemler için en düşüktür.

Algoritmaların yürütme sürelerine odaklanırsak, spektral tabanlı yöntemler genellikle spektral-uzamsal sınıflandırma yöntemlerinden daha hızlıdır. Fakat, LSRC algoritması

Tablo 4.11 Salinas, Indian Pines, Botswana veri kümeleri için yöntemlerin ortalama yürütme süreleri (saniye cinsinden)

Veri Kümesi	NSC	NRS	SaCRT	LSRC	CCJSR	JNSC	RJNSC	SVM-MV	RPNet	SKCR	WBNSC
Salinas	238.16	292.36	667.15	1236.92	1294.10	372.87	466.56	12.16	8.47	66.62	3941.51
Botswana	8.59	18.70	30.23	13.90	46.69	14.64	15.96	5.09	1.01	109.26	95.02
Indian Pines	17.99	29.02	29.46	105.78	100.30	27.16	29.57	2.13	1.81	16.61	249.95

içerisinde K-en yakın komşu yöntemi kullanılarak sözlük budama yapılması adımı ve SaCRT yönteminde yer alan yinelemeli optimizasyon adımları zaman almaktadır. Bu nedenle bu yöntemler, diğer spektral tabanlı yöntemlere göre daha yavaştır. Daha önce de belirtildiği gibi, pencere boyutu parametresi spektral-uzamsal sınıflandırma yöntemlerinde hesaplama süresini doğrudan etkilemektedir. RPNet ve SVM-MV yöntemlerinde, MATLAB içerisinden LIBSVM [162] toolbox'ı kullanılarak C programlama dilinde yazılmış fonksiyonlar çağırılmaktadır, bu nedenle bu yöntemler hızlıdır. RPNet'in basit bir ağ mimarisine sahip olması da hız açısından avantaj sağlamaktadır. JNSC ve RJNSC yöntemleri karşılaştırıldığında, RJNSC yöntemindeki düzenleştirme işleminin yürütme süresini önemli ölçüde artırmadığı görülmektedir. SKCR yöntemi süperpiksel bazında sınıflandırma yapması ve süperpiksel çıkarımı sırasında C ile yazılmış bir fonksiyonu çağırması nedeniyle hızlıdır.

Önerilen WBNSC yöntemi karşılaştırılan yöntemler arasında en yavaş olanıdır. WBNSC yönteminin yüksek hesaplama maliyetine sahip olmasının nedenleri; (i) önerilen yöntemdeki karmaşık işlemler (büyük matrislerle özdeğer özvektör ayrıştırması gibi), (ii) uzamsal bilginin kullanımı ve (iii) sınıfa özgü gösterimin kullanılmasıdır. (i)'den kaynaklanan hesaplama yükü, büyük ölçekli genelleştirilmiş özvektör hesaplaması için önerilen verimli algoritmalar kullanılarak aşılabılır [163]. (ii)'nin olumsuz etkisini önlemek için uzamsal pencere yerine süperpikseller kullanılabilir. Uzamsal pencereyi kullanarak piksel piksel sınıflandırma yapmak yerine, süperpikseller çıkarılabilir ve süperpiksel bazında sınıflandırma yapılabilir. Süperpiksel tabanlı yöntemlerdeki motivasyonlardan bir tanesi de pencere tabanlı yöntemlerdeki hesap maliyetini gidermektir. (iii)'nin olumsuz etkisinden kaçınmak için, önerilen yöntemde, her sınıf için iki altuzay arasındaki korelasyonu sıra ile hesaplamak yerine, dağıtılmış bir şekilde aynı anda altuzaylar arasındaki korelasyonlar hesaplanabilir.

Bu bölümde, pencere boyutu, eğitim verisi sayısı, test verisi sayısı, bant sayısı ve sınıf sayısı parametrelerinin önerilen WBNSC yönteminin hesap yüküne etkisi ayrı ayrı analiz edilmiştir. Sonuçlar Tablo 4.12’de verilmiştir. Deneyler, pencere boyutu 3’e, sınıf başına eğitim verisi sayısı 20’ye, test verisi sayısı 8344’e, bant sayısı 200’e ve sınıf sayısı 8’e ayarlanarak Indian Pines veri kümesi üzerinde gerçekleştirilmiştir. Diğer tüm parametreler sabit tutulacak şekilde sadece bir parametre değiştirilerek parametre değerlerinin yürütme süresine olan etkisi birer birer analiz edilmiştir. Penceredeki piksel sayısı, sınıf sayısı, test verisi boyutu ve eğitim verisi boyutu ile yürütme süresinin neredeyse doğrusal olarak arttığı görülmektedir.

Tablo 4.12 Değişen pencere boyutu, eğitim verisi sayısı, test verisi sayısı, bant sayısı ve sınıf sayısına göre önerilen WBNSC yönteminin yürütme süreleri (saniye cinsinden)

	Pencere Boyutu			Eğitim Verisi Sayısı			Test Verisi Sayısı			Bant Sayısı			Sınıf Sayısı		
	3×3	5×5	7×7	10	20	30	1000	2000	3000	50	100	150	2	4	6
Yürütme Süresi	22.93	64.27	130.75	15.75	22.93	29.67	3.72	7.47	11.37	14.01	19.38	21.11	5.86	11.09	17.18

Önerilen yöntem, karşılaştırılan yöntemler arasında en yavaşı olsa da, pencere boyutu parametresi için en uygun değer Bölüm 4.3.1.’de belirtildiği gibi basit bir ön bilgi ile kolaylıkla bulunabilir. RPNet gibi yöntemlerde ayarlanması gereken parametre sayısı fazladır ve bu parametreleri ayarlama işlemi, önerdiğimiz yöntemden daha zor ve zaman alıcıdır. Dahası, özellikle sınırlı eğitim verileriyle çapraz doğrulama gibi işlemler ile parametreler için optimum değer bulunması garanti değildir.

4.4. Önerilen Süperpiksel Tabanlı Yöntemler için Yapılan Deneyler

Bu bölümde, tez kapsamında önerilen yöntemlerin performansı Indian Pines ve Salinas veri kümeleri üzerinde JNSC [78], RJNSC [78], JSRC [66], SVM-MV [159], SKCR [160], derin öğrenme tabanlı bir yöntem olan RPNet [161] gibi spektral-uzamsal tabanlı yöntemler ile karşılaştırılmıştır. Bu bölümde ağırlıklı olarak önerilen süperpiksel tabanlı yöntemler, deneyler üzerinden yorumlanmıştır. İlk olarak önerilen süperpiksel tabanlı yöntemlerin çalışma mekanizmalarını anlaşılmasını sağlamak, birbirlerine göre avantajlarını/dezavantajlarını analiz etmek amacıyla Salinas verisi üzerinde sadece önerilen

yöntemler ile deneyler yapılmıştır. İkinci kısımda önerilen yöntemler, yukarıda bahsedilen spektral-uzamsal tabanlı yöntemler ile sınıf başına 20 eğitim örneği ile yapılan deneyler üzerinden karşılaştırılmıştır. Bunlara ek olarak farklı sınıf başına eğitim örnek sayıları (5, 10, 15, 20, 25, 30, 35, 40) için de deneyler yapılmış ve eğitim örneği sayısının yöntemlerin performansına etkisi incelenmiştir. Bu deneyler özelinde önerilen yöntemlerin birbirlerine ve karşılaştırma yapılan yöntemlere karşı üstünlükleri/eksiklikleri detaylı bir şekilde tartışılmıştır.


4.4.1. Parametre Düzenleme

Önerilen yöntemler ve deneyler sırasında karşılaştırma için kullanılan tüm yöntemlere ait hiper-parametreler için optimum değerler belirlenmiştir. Önerilen SBNSC yöntemi için süperpiksel sayısı parametresi için optimum değerler Salinas ve Indian Pines verileri için sırasıyla 1500, 400 olarak belirlenmiştir. Önerilen SBNSCMV yöntemi için süperpiksel sayısı parametresi için optimum değerler Salinas ve Indian Pines verileri için sırasıyla 1410 ve 750 olarak belirlenmiştir. MSBNSC yöntemi için Indian Pines verileri için 7 farklı ölçekte süperpiksel haritaları ile elde edilen sonuçlar ile en yüksek sınıflandırma performansları elde edilirken, Salinas verisi için 5 farklı ölçekte süperpiksel haritaları ile elde edilen sonuçlar ile en yüksek sınıflandırma performansları elde edilmiştir. Indian Pines verisi için bu farklı ölçeklerde süperpiksel sayısı değerleri 141, 200, 282, 400, 565, 800, 1314 olarak ve Salinas verisi için 800, 1131, 1600, 2262, 3200 olarak belirlenmiştir.

4.4.2. Önerilen Yöntemlerin Karşılaştırmalı Analizi

Bu kısımda önerilen yöntemlerin birbirlerine göre avantajlarını/dezavantajlarını analiz etmek ve çalışma mekanizmalarını gerçek veri üzerinde analiz etmek amacıyla Salinas verisi üzerinde deneyler yapılmıştır. İlk olarak önerdiğimiz pencere tabanlı yöntem WBNSC ile süperpiksel tabanlı yöntem SBNSC karşılaştırılmıştır. Şekil 4.18’de ilk sınıflandırma haritası WBNSC yöntemine ait sınıflandırma haritasını, sonraki iki sınıflandırma haritası SBNSC’ye ait sınıflandırma haritasını göstermektedir. SBNSC’ye ait ilk görselde, görüntüden çıkarılan

süperpikseller de verilmiştir. SBNSC’ye ait ikinci sınıflandırma haritası SBNSC yöntemi ile alınan sonuçları daha net görebilmek amacıyla süperpiksellerin gösterilmediği sınıflandırma haritasıdır.




Şekil 4.18 Salinas verisi üzerinde WBNSC ve SBNSC yöntemlerine ait sınıflandırma haritalarının karşılaştırması (a) WBNSC yöntemi ile elde edilen sınıflandırma haritası (b) SBNSC yöntemi ile elde edilen sınıflandırma haritası süperpikseller ile birlikte verilmiştir. (c) SBNSC yöntemi ile elde edilen sınıflandırma haritası.

Şekil 4.18’de WBNSC ile alınan sonuçlar incelendiğinde sarı elipsler ile işaretlenen bölgelerde sınıf sınırlarında yanlış sınıflandırmalar olmaktadır. Bunun nedeni, pencere içerisine farklı sınıflardan örnekler girmesidir. Önerdiğimiz SBNSC yönteminde ise süperpikseller ile sınıf sınırlarının düzgün bir şekilde bulunabildiği ve çıkarılan süperpiksellerin genelde homojen olduğu görülmektedir. Böylece SBNSC yönteminde sınıf sınırlarında bu tarz problemler pek yaşanmamaktadır. Bununla birlikte, WBNSC yöntemine ait sınıflandırma haritası içerisinde sarı kare ile işaretlenmiş bölgelerde yanlış sınıflandırılmış tekli pikseller bulunmaktadır. Süperpiksel tabanlı SBNSC yöntemi ile bunlar da giderilmektedir. Büyük düzgün bölgeler içeren görüntüler için süperpiksel tabanlı yöntemlerin avantaj sağladığı gözlenmektedir.

Öte yandan, SBNSC yöntemine ait sınıflandırma haritası içerisinde pembe kare ile işaretlenmiş bölgelerde yanlış sınıflandırılmış süperpikseller bulunmaktadır. Bu alanlar

süperpiksellerin etrafındaki süperpikseller hesaba katılarak giderilebilir. Bu amaçla tez kapsamında SBNSCMV yöntemi önerilmiştir. Şekil 4.19’da SBNSC yöntemi ve SBNSCMV yöntemine ait sınıflandırma haritaları verilmiştir. Şekil 4.19’da ilk sınıflandırma haritası SBNSC’ye ait sınıflandırma haritasını göstermektedir, 2. ve 3. sınıflandırma haritaları ise SBNSC-MV yöntemine ait haritalardır. SBNSCMV yöntemine ait ilk sınıflandırma haritasında SBNSCMV yönteminde son işleme (çoğunluk oylama) fazı yapılmadan önceki durumda elde edilen sınıflandırma haritası süperpiksellerle birlikte verilmiştir. SBNSCMV yöntemine ait ikinci sınıflandırma haritası ise SBNSCMV yöntemi için komşu süperpikseller kullanılarak çoğunluk oylama uygulandıktan sonra elde edilen sınıflandırma haritasını göstermektedir.




Şekil 4.19 Salinas verisi üzerinde SBNSC ve SBNSCMV yöntemlerine ait sınıflandırma haritalarının karşılaştırması. (a) SBNSC yöntemi ile elde edilen sınıflandırma haritası, (b) SBNSCMV yöntemi çoğunluk oylama fazı yapılmadan önce elde edilen sınıflandırma haritası, (c) SBNSCMV yöntemi için çoğunluk oylama fazı uygulandıktan sonra elde edilen sınıflandırma haritası.

Şekil 4.19 incelendiğinde SBNSC sınıflandırma haritasında pembe kare ile işaretlenmiş bölgelerde büyük yanlış sınıflandırılmış alanlar bulunmaktadır. Önerilen SBNSCMV yönteminde test süperpikseline bitişik olan süperpiksellerin kestirilen etiketlerine bakılarak çoğunluk oylama ile test süperpikselinin nihai etiketine karar verilmektedir. Bu son aşama

sayesinde Şekil 4.19’da görüldüğü gibi yanlış sınıflandırılmış süperpikseller ekstra uzamsal bilgi ile düzeltilebilmektedir.

Önerilen SBNSC yönteminin bir diğer dezavantajı süperpiksel boyutu (süperpiksel sayısı) için optimum değerin belirlenmesi problemidir. Bu problemin giderilmesi için birden fazla ölçekle elde edilmiş süperpiksellerden birlikte yararlanan MSBNSC yöntemi tez kapsamında önerilmiştir. MSBNSC yöntemi için Salinas veri kümesi için önerilen MSBNSC yönteminde 5 farklı ölçekte elde edilen süperpikseller kullanılarak sınıflandırma yapılmıştır. Şekil 4.20’de ilk iki görselde bu 5 farklı ölçekten 2 tanesi ile elde edilen sınıflandırma haritaları süperpiksellerle birlikte verilmiştir. Üçüncü görselde ise farklı ölçekler için elde edilen sınıflandırma haritalarındaki etiketlerin piksel bazında çoğunluk oylama fazı uygulandıktan sonra elde edilen nihai sınıflandırma haritası verilmiştir.



Şekil 4.20 Salinas veri kümesi üzerinde MSBNSC yöntemi için ara aşamalara ait sınıflandırma haritaları ve nihai sınıflandırma haritası. (a) Ölçek 1 ile elde edilen sınıflandırma haritası (Süperpiksel sayısı az/süperpiksel boyutları büyük), (b) Ölçek 5 ile elde edilen sınıflandırma haritası (Süperpiksel sayısı çok/süperpiksel boyutları küçük), (c) MSBNSC yöntemi için nihai sınıflandırma haritası.

Bu deney ile süperpiksel boyutunun sınıflandırmaya olan etkisinin de gözlemlenmesi amaçlanmaktadır. Ölçek 1’de seçilen süperpiksel sayısı küçük, süperpiksel boyutları büyüktür. Süperpiksellerin boyutu büyük olduğunda bir süperpiksel içerisinde farklı

sınıflara ait piksellerin olma ihtimali artmaktadır, bu da Şekil 4.20’de görüldüğü gibi yanlış sınıflandırılmış büyük süperpiksellerin olmasına neden olmaktadır. Süperpiksellerin boyutunun küçük olması durumunda uzamsal açıdan yeterli bilgi sağlamamaktadır ve piksel bazlı sınıflandırmadan farkı kalmamaktadır. Ayrıca farklı ölçekler ile elde edilen süperpikseller görüntüdeki farklı morfolojik yapıları yakalayabilmektedir. Ölçek 1 ve ölçek 5 ile elde edilen sınıflandırma haritalarına bakıldığında farklı morfolojik yapıların yakalandığı ve farklı alanlarda sınıflandırma hatalarının olduğu göze çarpmaktadır; fakat son aşamada piksel bazında karar birleştirme ile elde edilen nihai sınıflandırma haritasında daha pürüzsüz alanlar elde edilmekte ve farklı ölçekler ile elde edilen sınıflandırma hataları giderilmektedir. Ancak, önerilen MSBNSC yöntemi için bu ölçek değerlerinin belirlenmesi kolay değildir.


Her yöntemin birbirlerine karşı üstünlükleri ve zaafı bulunmaktadır. Yöntemlerin performansı görüntü içerisindeki sınıfların boyutuna, yapısına, birbirlerine olan yakınlıklarına doğrudan bağlıdır. Önerilen yöntemlerin performansları ilerleyen kısımlarda farklı morfolojik yapılar içeren veri kümeleri üzerinde detaylıca incelenmiştir.

4.4.3. Salinas Veri Kümesi ile Yapılan Deneyler

Salinas verisi için önerilen yöntemler ve karşılaştırılan diğer yöntemler ile elde edilen sınıflandırma haritaları Şekil 4.21’de verilmiştir. Ayrıca, bu veri kümesi için yöntemlerin her bir sınıf için ayrıntılı sınıflandırma performansları Tablo 4.13’te verilmiştir.

Şekil 4.21’de yer alan sınıflandırma haritaları incelendiğinde pencere tabanlı yöntemlerde sınıf sınırlarında yanlış sınıflandırılmış pikseller görülmektedir. Bu duruma en belirgin örnekler; JNSC, RJNSC yöntemleri ile elde edilen sınıflandırma haritalarında görülmektedir. Örneğin, C13 sınıfı içerisinde C14 sınıfına yakın kenarlarda yanlış sınıflandırılmış (C14 sınıfına atanmış) pikseller bulunmaktadır. Benzer örnekler C5, C9 ve C14 sınıfları içerisinde de bulunmaktadır. Bu yöntemler ile elde edilen sınıflandırma haritalarında görüldüğü kadar belirgin olmasa da SVM-MV yöntemi ile alınan sonuçlarda C10, C13, C14 ve RPNet yöntemi ile alınan sonuçlarda ise C2, C5 ve C14 sınıflarının sınırlarında da yanlış sınıflandırılmış pikseller görülmektedir. Benzer durumlar WBNSC ile elde edilmiş

sınıflandırma haritasında C4 ve C5 gibi sınıflarda da görülmektedir. Bu tür örnekler SKCR ve önerdiğimiz süperpiksel tabanlı yöntemlerde de görülse de bahsettiğimiz yöntemlere göre çok daha az orandadır. Süperpiksel kullanımı özellikle sınıf sınırlarında yer alan piksellerin sınıflandırılmasında avantaj sağlamaktadır.



Şekil 4.21 Salinas verisi için önerilen yöntemler ve karşılaştırılan diğer yöntemler ile elde edilen sınıflandırma haritaları. Sınıf başına 20 örnek eğitim verisi olarak kullanılmış, geriye kalan örnekler test verisi olarak kullanılmıştır.


Tablo 4.13 incelendiğinde birçok yöntem C8 ve C15 sınıflarını doğru sınıflandırmada zorlanmıştır ve bu iki sınıfın birbirine karıştırıldığı görülmektedir. Şekil 4.21’de SKCR yöntemine ait sınıflandırma haritasında C8 sınıfında bu tür yanlış sınıflandırmış alanlar görülmektedir. SKCR yönteminde süperpiksel sayısı küçük seçilmiştir. Bu yüzden süperpiksel boyutları büyüktür ve C8 sınıfı içerisinde büyük yanlış sınıflandırılmış alanlar görülmektedir. Benzer yanlış sınıflandırılmış alanlar önerilen yöntemlerde C15 sınıfında görülmektedir. Bu alanlar SBNSCMV yönteminde en azdır, çünkü bu yöntemde süperpiksel

Tablo 4.13 Salinas verisi için önerilen yöntemlerin ve karşılaştırılan diğer yöntemlerin sınıflandırma doğrulukları (%)

Sınıf	JNSC	RJNSC	SVM-MV	RPN _{et}	SKCR	WBNSC	SBNSC	SBNSCMV	MSBNSC
C1	99.41	99.61	100.00	94.93	100.00	<u>99.63</u>	99.42	99.36	99.53
C2	99.44	98.81	<u>99.99</u>	91.24	100.00	100.00	99.94	99.94	100.00
C3	99.64	99.91	96.43	96.78	<u>99.93</u>	100.00	100.00	100.00	100.00
C4	99.25	98.87	99.88	97.79	97.30	95.33	98.10	98.44	99.59
C5	88.41	91.54	98.26	97.54	99.18	98.78	<u>99.30</u>	99.37	99.12
C6	97.11	97.28	99.76	98.97	99.66	99.36	<u>99.89</u>	<u>99.89</u>	99.90
C7	97.25	97.21	99.98	94.88	99.91	99.98	99.93	<u>99.96</u>	99.88
C8	71.45	80.58	63.84	79.41	87.65	84.08	91.64	95.06	91.89
C9	94.08	94.79	99.52	98.37	99.61	99.99	99.81	<u>99.98</u>	<u>99.98</u>
C10	95.69	95.40	95.74	<u>97.52</u>	95.27	95.80	96.11	98.51	96.52
C11	98.39	98.52	99.75	98.48	99.64	99.72	99.28	100.00	<u>99.96</u>
C12	<u>99.87</u>	75.00	100.00	97.47	97.23	96.33	99.64	99.04	97.95
C13	<u>93.08</u>	69.72	99.39	<u>98.62</u>	98.13	95.31	97.67	92.35	96.70
C14	96.58	95.66	<u>98.98</u>	96.93	93.09	99.02	95.58	94.23	96.60
C15	68.08	64.13	69.83	<u>81.33</u>	92.77	77.83	74.76	79.06	78.35
C16	98.49	98.54	98.57	97.61	97.41	99.25	<u>99.26</u>	99.29	98.99
OA(%)	87.46	87.75	87.74	91.06	<u>95.62</u>	92.93	94.30	95.66	94.86
AA(%)	93.51	90.97	94.99	94.87	97.29	96.27	96.90	97.15	<u>97.18</u>
κ (%)	86.06	86.34	86.41	90.07	<u>94.80</u>	92.13	93.64	94.97	94.27

bazında çoğunluk oylama son işleme aşaması kullanılmaktadır. Bu son işleme aşaması büyük pürüzsüz (smooth) bölgelerin olduğu ve spektral imzası benzer olan sınıfların bulunduğu Salinas gibi sahneler için işe yaramaktadır ve bu son aşama fazı SBNSCMV yöntemine bu veri kümesi için avantaj sağlamaktadır.

Tablo 4.13'te yöntemlerin sınıf bazında sınıflandırma performanslarına bakıldığında SMV-MV yöntemi beş tane sınıfta en yüksek performansa sahip olsa da genel doğruluğa (OA) bakıldığında yöntemler arasında 6. sıradadır. Bunun nedeni SVM-MV yönteminin en yüksek performansa sahip olduğu sınıflarda yöntemler arası performans farklarının çok düşük olmasıdır. Önerilen süperpiksel tabanlı yöntemlerin OA bazındaki performansı SKCR hariç diğer yöntemlerden çok daha üstündür. Bu sonuçlar, süperpiksel kullanımının, pencere kullanımına kıyasla avantaj sağladığını doğrulamaktadır. Ayrıca ilerleyen bölümlerde farklı eğitim örneği sayıları ile yapılan deneyler de paylaşılmıştır ve önerilen yöntemlerin sınırlı eğitim verisi olması durumunda diğer yöntemlere göre daha etkili olduğu gözlemlenmiştir.



Şekil 4.22 Indian Pines verisi için önerilen yöntemler ve karşılaştırılan diğer yöntemler ile elde edilen sınıflandırma haritaları. Sınıf başına 20 örnek eğitim verisi olarak kullanılmış, geriye kalan örnekler test verisi olarak kullanılmıştır.

4.4.4. Indian Pines Veri Kümesi ile Yapılan Deneyler

Indian Pines verisi için önerilen yöntemler ve karşılaştırılan diğer yöntemler ile elde edilen sınıflandırma haritaları Şekil 4.22’de verilmiştir. Ayrıca, bu veri kümesi için yöntemlerin her bir sınıf için ayrıntılı sınıflandırma performansları Tablo 4.14’te verilmiştir.

Bu veri kümesinde sınıf bölgeleri birbirine çok yakındır. Bu, Şekil 4.22’de görüldüğü gibi pencere tabanlı yöntemlerin (WBNSC, SVM-MV, JNSC, RJNSC) performansını olumsuz yönde etkilemektedir ve sınıf sınırlarında yanlış sınıflandırılmış piksellere yol açmaktadır. Sahnenin sol ortasında birbirine yakın şekilde alt alta bulunan C2 ve C7 sınıflarına baktığımızda C2 sınıfının C7 sınıfına yakın kenarında bu yöntemler ile elde edilen sınıflandırma haritalarında yanlış sınıflandırılmış pikseller bulunduğu görülmektedir. Benzer yanlış sınıflandırılmış pikseller farklı sınıfların kenarlarında bulunan piksellerde de görülmektedir. Öte yandan, SKCR, MSBNSC ve SBNSC gibi süperpiksel tabanlı yöntemlerin sınıflandırma haritaları, pencere tabanlı yöntemlere kıyasla sınıf sınırlarında daha az hatalı sınıflandırılmış piksel içermektedir.

Pencere tabanlı yöntemlerde, piksel bazında sınıflandırma yapılmaktadır. Pencerede gürültülü piksellerin varlığı, pencere tabanlı yöntemlere ait sınıflandırma haritalarında görüldüğü gibi yanlış sınıflandırılmış tekli piksellere yol açmaktadır. Süperpiksel tabanlı yöntemler, bu yanlış sınıflandırılmış tekli piksellerin oluşmasını önlemektedir. Böylece süperpiksel tabanlı yöntemlerle elde edilen sonuçlar daha pürüzsüz bölgeler içermektedir. Bununla birlikte, süperpikseller içerisinde gürültülü pikseller yer alması süperpiksel tabanlı yöntemlerde yanlış sınıflandırılmış süperpiksellere neden olmaktadır. Şekil 4.22’de tüm süperpiksel tabanlı yöntemlerin sınıflandırma haritalarında bu tarz yanlış sınıflandırılmış büyük bölgeler göze çarpmaktadır.

Tablo 4.14’te verilen sonuçlara bakıldığında önerilen MSBNSC yöntemi, sekiz sınıf arasından dört sınıfta en yüksek doğruluğa ve üç sınıfta ikinci en yüksek doğruluğa sahiptir. Ayrıca, genel doğruluk ve ortalama doğruluk açısından diğer yöntemlerden daha iyi performans göstermektedir. SBNSCMV yöntemi Salinas veri kümesinde en yüksek sınıflandırma

Tablo 4.14 Indian Pines verisi için önerilen yöntemlerin ve karşılaştırılan diğer yöntemlerin sınıflandırma doğrulukları

Sınıf	JNSC	RJNSC	SVM-MV	RPNNet	SKCR	WBNSC	SBNSC	SBNSCMV	MSBNSC
C1	51.61	59.50	63.28	75.22	71.84	66.38	69.70	69.77	<u>73.70</u>
C2	41.48	55.62	61.09	<u>89.85</u>	84.71	83.38	82.57	86.93	89.96
C3	85.16	90.15	91.42	90.36	91.16	89.50	93.82	90.54	<u>92.19</u>
C4	97.62	97.57	99.56	97.66	<u>99.94</u>	99.65	100.00	99.51	100.00
C5	66.11	75.45	76.34	80.86	<u>78.36</u>	82.31	79.77	<u>82.67</u>	82.99
C6	45.95	61.91	66.24	<u>76.20</u>	79.38	71.53	75.72	74.05	72.37
C7	49.14	65.37	80.54	93.28	85.69	90.45	91.37	88.21	<u>93.14</u>
C8	97.24	95.94	98.30	91.99	98.87	99.25	<u>99.75</u>	98.94	99.82
OA(%)	61.65	71.28	75.38	83.38	<u>83.58</u>	81.01	82.83	82.56	83.65
AA(%)	66.79	75.19	79.60	<u>86.93</u>	86.24	85.30	86.59	86.33	88.02
κ (%)	54.82	65.85	70.85	80.24	<u>80.31</u>	77.47	79.61	79.30	80.58


performansına sahip olmasına rağmen, bu veri kümesinde diğer yöntemlerin gerisinde kalmıştır. Bunun nedeni, Indian Pines veri kümesinin iç içe sınıflar içermesi ve bu veri kümesinde yer alan sınıfların daha küçük alanlara sahip olmasıdır. Bu tarz nedenlerden dolayı, SBNSCMV yönteminde kullanılan son işleme aşaması bu veri kümesinde Salinas veri kümesinde olduğu kadar etkili olamamaktadır. Indian Pines veri kümesinin Salinas veri kümesinden ayrıldığı bir diğer nokta ise bu veri kümesinin çok karmaşık morfolojik yapılar içermesidir. Bu farklılıkları tek bir süperpiksel ölçeği ile yakalamak zor olabilmektedir. Bu yüzden çoklu ölçek kullanan MSBNSC yöntemi bu tür veri kümelerinde daha avantajlıdır. Tablo 4.14’te verilen sonuçlar da bunu doğrular niteliktedir.

MSBNSC’nin genel doğruluğu SKCR, RPNNet yöntemlerinden sırasıyla yaklaşık olarak %0.07 ve %0.27 daha yüksektir ve diğerler yöntemler ile arasındaki fark daha da yüksektir. Ayrıca ilerleyen bölümlerde farklı eğitim örneği boyutları ile yapılan deneyler de paylaşılmıştır ve önerilen yöntemlerin eğitim verisi sayısı sınırlı olduğu durumlarda diğer yöntemlere göre daha etkili olduğu gözlemlenmiştir.

4.4.5. Eğitim Örneği Sayısının Yöntemlerin Sınıflandırma Performansına Etkisi

Bu kısımda, önerilen yöntemlerin performansı sınıf başına farklı sayıda eğitim örnekleri (5, 10, 15, 20, 25, 30, 35, 40) için diğer yöntemlerle karşılaştırılmıştır. Salinas ve Indian Pines

veri kümelerine ait sınıf başına farklı sayıda eğitim örnekleri için yöntemlerin sınıflandırma performansları (OA) Şekil 4.23'te verilmiştir.



Şekil 4.23 Yöntemlerin (a) Salinas, (b) Indian Pines veri kümeleri üzerinde değişen sınıf başına eğitim örneği sayıları için sınıflandırma performansları

Salinas verisinde sınırlı veri (5-10 eğitim verisi) ile elde edilen performanslara bakılığında önerilen SBNSC-MV ve MSBSNC yöntemlerine ait performanslar, diğer yöntemlere karşı belirgin bir şekilde üstündür. Bu yöntemleri SKCR yöntemi izlemektedir, önerilen yöntemler SKCR yönteminden bile %5 daha yüksek performans göstermektedir. Diğer yöntemlerden ise %8 ve daha yüksek performansa sahiptir. SKCR yöntemi eğitim verisi sayısı arttıkça arayı kapatmaktadır. Sınıf başına 15 eğitim verisi ile elde edilen sonuçlarda da önerdiğimiz

yöntemlerin performansı daha yüksek olsa da sınıf başına eğitim verisi sayısı 20 olduğu durumda SKCR yöntemi, önerdiğimiz yöntemleri neredeyse yakalamakta ve daha büyük eğitim verileri kullanıldığında önerilen yöntemlerin performansını geçmektedir. Ama aradaki performans farkı çok yüksek değildir, %0-%1 bandındadır. Karşılaştırılan diğer tüm yöntemlerin performansı bütün koşullar için önerdiğimiz yöntemlerden daha düşüktür.

Indian Pines verisi için de eğitim verisi sayısı 5, 10, 15, 20 ve 30 için en yüksek performans MSBNSC yöntemi ile elde edilmiştir. Özellikle eğitim verisi sınırlı olduğunda önerilen yöntemler daha iyi performans göstermektedir. Eğitim verisi arttığında RpNet'in performansı önerilen yöntemleri geçmektedir. Önceki kısımlarda da belirtildiği gibi HSG işleme alanında etiketli verilere erişim zor ve maliyetlidir. Bu nedenle, önerilen yöntemlerin eğitim verisi sayısı sınırlı olduğu durumlarda diğer yöntemlere kıyasla daha iyi performans göstermesi oldukça kıymetlidir.

4.5. Müsilaj Tespiti Deneyleri

Bu bölümde, tez kapsamında önerilen yöntemlerin performansı İstanbul ve Bursa müsilaj verileri üzerinde JNSC [78], RJNSC [78], JSRC [66], SVM -MV [159], SKCR) [160], derin öğrenme tabanlı bir yöntem olan RpNet [161] gibi spektral-uzamsal tabanlı yöntemler ile karşılaştırılmıştır. Bu bölümdeki deneylerin ilk kısmında aynı veri kümesi içerisinde eğitim ve test verileri alınmış, bu veriler ile yöntemlerin performansları karşılaştırılmıştır. İkinci kısımda ise Bursa veri kümesinden eğitim verisi alınarak İstanbul veri kümesi üzerinde test edilmiştir ve İstanbul veri kümesinden eğitim verisi alınarak Bursa veri kümesi üzerinde test edilmiştir. Böylece farklı gün ve konumdan eğitim verileri alındığı durumda yöntemlerin performanslarının nasıl etkilendiği incelenmiştir. Tüm deneyler sırasında sınıf başına 20 eğitim verisi kullanılmıştır.

Müsilaj tespiti gibi tespit problemlerinde kullanılan temel kavramlardan bazıları aşağıda verilmiştir;

- P: Veri içerisindeki müsilaj örnek (pozitif örnek) sayısını ifade etmektedir.

- N: Veri içerisindeki deniz örnek (negatif örnek) sayısını ifade etmektedir.
- TP (Gerçek Pozitif, True Positive): Yöntem tarafından doğru tahmin edilen pozitif örnek sayısını ifade etmektedir.
- TN (Gerçek Negatif, True Negative): Yöntem tarafından doğru tahmin edilen negatif örnek sayısını ifade etmektedir.
- FP (Yanlış Pozitif, False Positive): Gerçekte negatif (deniz) olmasına rağmen yöntem tarafından pozitif (müsilaj) olarak tahmin edilen örnek sayısını ifade etmektedir.
- FN (Yanlış Negatif, False Negative): Gerçekte pozitif (müsilaj) olmasına rağmen yöntem tarafından negatif (deniz) olarak tahmin edilen örnek sayısını ifade etmektedir.

Bu yöntemleri sayısal olarak karşılaştırabilmek için kullanılan parametreler ve başarı ölçütleri aşağıda sıralanmıştır:

- TPR (Gerçek Pozitif Oran, True Positive Rate, Sensitivity, Duyarlılık, Recall) = TP/P .
- FPR (Yanlış Pozitif Oran, False Positive Rate) = FP/N ,
- TNR (Gerçek Negatif Oran, True Negative Rate, Specifity) = TN/N
- FNR (Yanlış Negatif Oran, False Negative Rate) = FN/P ,
- AA (Ortalama Doğruluk, Average Accuracy, Balanced Accuracy) = $(TPR + TNR)/2$,
- OA (Genel Doğruluk, Overall Accuracy) = $(TP + TN)/(P+N)$

Müsilaj veri kümelerinde deniz ve müsilaj örneklerinin sayısında dengesizlik göze çarpmaktadır. Bu nedenle bu tarz veri kümelerinde genel doğruluk (OA) yerine yöntemleri karşılaştırmak için ortalama doğruluğu (AA) baz almak daha uygun olmaktadır.

4.5.1. Parametre Düzenleme

Müsilaj tespiti için yapılan deneylerde de tüm yöntemlerin hiper-parametreleri en uygun şekilde ayarlanmıştır. Önerilen SBNSC yöntemi için süperpiksel sayısı parametresi için optimum değerler İstanbul ve Bursa müsilaj verileri için sırasıyla 4000 ve 42000 olarak belirlenmiştir. Önerilen SBNSCMV yöntemi için süperpiksel sayısı parametresi için optimum değerler İstanbul ve Bursa müsilaj verilerinin her ikisi için de 32000 olarak belirlenmiştir. MSBNSC yöntemi için İstanbul ve Bursa müsilaj verileri için sırası ile 7 ve 5 farklı ölçekte süperpiksel haritaları ile elde edilen sonuçlar ile en yüksek sınıflandırma performansları elde edilmiştir. İstanbul müsilaj verisi için bu farklı ölçekler için süperpiksel sayısı değerleri 1414, 2000, 2828, 4000, 5657, 8000, 11314 olarak; Bursa müsilaj verisi için 22627, 32000, 45255, 64000, 90510 olarak ayarlanmıştır.

Çoğunluk oylamalı destek vektör makinesi, JNSC, RJNSC, WBNSC yöntemleri için tüm müsilaj veri kümelerinde en uygun pencere boyutu 3 olarak belirlenmiştir. Bu veri kümelerinde pencere boyutu küçük seçildiğinde performansın yüksek çıkması müsilaj sınıfına ait örneklerin sahnede ince yapılarda olmasından kaynaklanmaktadır. RJNSC için, optimal düzenleme parametresi değeri ve yineleme sayısı İstanbul ve Bursa müsilaj verilerinin her ikisi için de sırasıyla 10^{-2} ve 50 olarak ayarlanmıştır. SKCR için süperpiksel sayısı parametresi İstanbul müsilaj verisi için 400, Bursa müsilaj verisi için 3500 olarak ayarlanmıştır, en yakın komşu oranı, tradeoff parametresi her iki müsilaj veri kümesi için de sırasıyla 0.5 ve 0.07 olarak ayarlanmıştır. RPNet yöntemi parametreleri; yama sayısı, yama boyutu, temel bileşenlerin sayısı ve ağı derinliği tüm müsilaj verileri için de sırasıyla 20, 21, 3 ve 5 olarak ayarlanmıştır.

4.5.2. İstanbul Müsilaj Verisi ile Yapılan Deneyler


Bu bölümde İstanbul müsilaj verisi üzerinde deneyler gerçekleştirilmiştir. İstanbul Müsilaj veri kümesi için sınıf başına 20 eğitim örneği ile elde edilen farklı yöntemlerin sınıflandırma haritaları Şekil 4.24'te verilmiştir. Ayrıca, yöntemlerin her bir sınıf için

ayrıntılı sınıflandırma performansları Tablo 4.15'te verilmiştir. Şekil 4.24'te yer alan sınıflandırma haritaları incelendiğinde önerilen yöntemlere ait sınıflandırma haritalarının rekabetçi yöntemlere kıyasla yer gerçekliği görüntüsüne daha çok benzediği ilk etapta göze çarpmaktadır. SKCR, RpNet ve SVM-MV yöntemleri çok fazla yanlış pozitif örnek içermektedir. Tablo 4.15'te de bu yöntemlere ait FPR değerlerinin diğer yöntemlere kıyasla daha yüksek olduğu gözlemlenmektedir. Sınıflandırma haritalarına bakıldığında müsilaaj tespitinde en çok zorlanan yöntemin SVM-MV yöntemi olduğu görülmektedir. Tablo 4.15'te de en düşük TPR değerine sahip yöntem SVM-MV yöntemidir. Şekil 4.24'te dikkat çeken bir diğer nokta ise yer-gerçekliği görüntüsünde yer almayan fakat ilgili koşu için hemen hemen tüm yöntemler ile elde edilen sınıflandırma haritalarında sahnenin sol üst kısmında tespit edilen müsilaajlardır. Diğer koşullara ait sınıflandırma haritaları da incelenmiş buralarda bu bölgede müsilaaj tespit edildiği gözlemlenmiştir. Bu da akla, buradaki piksellerin doğru etiketlenmediği ihtimalini getirmektedir.

Önerilen WBNSC yöntemi de dahil olmak üzere JNSC, RJNSC ve RpNet gibi pencere tabanlı yöntemler müsilaajları yer-gerçekliği görüntüsünde olduğu gibi ince bir çizgi halinde bulabilmektedir. Önerilen süperpiksel tabanlı yöntemlerden SBNSC ve MSBNSC yöntemleri ise müsilaajları biraz kalın bir şekilde tespit etmektedir. Bu da müsilaajların etrafında yanlış pozitif örneklerin elde edilmesine neden olmaktadır. Fakat, bu yöntemler bu örnekler haricinde çok fazla yanlış pozitif örnek içermemektedir ve bu yöntemlere ait sınıflandırma haritaları, yer-gerçekliği görüntüsüne en çok benzeyen haritalardır.

Tablo 4.15 İstanbul müsilaaj verisi için önerilen yöntemlerin ve karşılaştırılan diğer yöntemlerin sınıflandırma doğrulukları (%)

Sınıf	JNSC	RJNSC	SVM-MV	RpNet	SKCR	WBNSC	SBNSC	SBNSCMV	MSBNSC
TNR (C1)	89.61	92.24	80.29	88.31	83.65	95.43	<u>96.71</u>	95.30	97.08
FPR	10.39	7.76	19.71	11.69	16.35	4.57	<u>3.29</u>	4.70	2.92
TPR (C2)	99.85	99.96	62.49	98.89	98.23	<u>99.89</u>	98.71	96.47	98.51
FNR	0.15	0.04	37.51	1.11	1.77	<u>0.11</u>	1.29	3.53	1.49
OA(%)	89.64	92.27	80.23	88.35	83.70	95.44	<u>96.72</u>	95.30	97.08
AA(%)	94.74	96.10	71.40	93.61	90.94	97.66	<u>97.71</u>	95.89	97.80



Şekil 4.24 İstanbul müsilaaj verisi için önerilen yöntemler ve karşılaştırılan diğer yöntemler ile elde edilen sınıflandırma haritaları. Sınıf başına 20 örnek eğitim verisi olarak kullanılmış, geriye kalan örnekler test verisi olarak kullanılmıştır.

Önerilen yöntemler dışındaki yöntemler arasından yer gerçekliği görüntüsüne en çok benzeyen sınıflandırma haritası RJNSC yöntemine aittir. Tablo 4.15 de bunu doğrular nite-liktedir. RJNSC, C2 sınıfında (müsilaj) en iyi performansı göstermektedir. Fakat, RJNSC yönteminin C1 sınıfı için sınıflandırma doğruluğu önerilen yöntemlere göre daha düşüktür ve daha fazla yanlış pozitif örnek içermektedir.


Ortalama doğrulukta (AA) ve genel doğrulukta (OA) en iyi performansa sahip yöntemler sırasıyla önerdiğimiz MSBNSC, SBNSC, WBNSC ve SBNSCMV yöntemleridir ve diğer yöntemlere kıyasla performansları belirgin bir şekilde üstündür.

4.5.3. Bursa Müsilaj Verisi ile Yapılan Deneyler

Bursa Müsilaj veri kümesi için sınıf başına 20 eğitim örneği için elde edilen farklı yöntemlerin sınıflandırma haritaları Şekil 4.25'te verilmiştir. Ayrıca, yöntemlerin her bir sınıf için ayrıntılı sınıflandırma performansları Tablo 4.16'da verilmiştir.

Şekil 4.25 incelendiğinde, karşılaştırma için kullanılan yöntemler genel anlamda müsila- ları buluyor olsa da çok fazla yanlış pozitif örnek içermektedir. Özellikle SVM-MV ve RPNet ile elde edilen sonuçlar çok fazla yanlış pozitif örnek içermektedir. Tablo 4.16 incelendiğinde de en yüksek FPR değerleri bu yöntemlere aittir. Buna ek olarak sınıflandırma haritaları incelendiğinde müsila- j tespitinde en çok zorlanan ve Tablo 4.16'da en düşük TPR değerine sahip yöntem SVM-MV yöntemidir. Şekil 4.25'te dikkat çeken bir diğer nokta ise sahnede sağ üstte ince çizgi halinde yer alan müsila- jların aşağıya doğru bir uzantısının olabileceği ve buradaki piksellerin doğru etiketlenmediği ihtimalidir. Yer-gerçekliği görüntüsünde olmasa da JNSC, RJNSC yöntemleri ve önerilen yöntemler ile elde edilen sınıflandırma haritalarında bu uzantı göze çarpmaktadır.

Şekil 4.25'te en temiz gözüken (yanlış pozitif içeren) yöntem SBNSCMV yöntemidir. Tablo 4.16 incelendiğinde de SBNSCMV yöntemi, C1 sınıfını sınıflandırmada en iyi sonuçları vermektedir. Fakat C2 sınıfı için SBNSCMV yönteminin performansı diğer yöntemlere göre çok düşüktür. Bu, SBNSCMV yönteminin müsila- j örneklerini bulmada diğer yöntemlere



Şekil 4.25 Bursa müsilaç verisi için önerilen yöntemler ve karşılaştırılan diğer yöntemler ile elde edilen sınıflandırma haritaları. Sınıf başına 20 örnek eğitim verisi olarak kullanılmış, geriye kalan örnekler test verisi olarak kullanılmıştır.

kıyasla zorlandığını göstermektedir. Bunun nedeni, veri kümesinde test örnekleri içerisinde deniz örnekleri sayısının müsilağ örneklerine göre çok daha fazla olmasından ve SBNSCMV yönteminin son işleme sırasında çoğunluk oylama yaklaşımını kullanmasından kaynaklanmaktadır. Bu yüzden SBNSCMV yöntemi süperpikselleri ağırlıklı olarak deniz sınıfına atamaya meyillidir. Bu nedenle, Şekil 4.25'te görüldüğü üzere SBNSCMV yöntemi, sahnenin solunda ince çizgiler halinde bulunan müsilağ örneklerini tespit edememektedir. Önerilen WBNSC, SBNSC, MSBNSC yöntemleri ile elde edilen sonuçlarda C1 ve C2 sınıflarına ait başarımlar SBNSCMV yöntemine göre daha dengelidir.

Tablo 4.16 Bursa müsilağ verisi için önerilen yöntemlerin ve karşılaştırılan diğer yöntemlerin sınıflandırma doğrulukları (%)

Sınıf	JNSC	RJNSC	SVM-MV	RPN _{et}	SKCR	WBNSC	SBNSC	SBNSCMV	MSBNSC
TNR (C1)	87.41	91.26	72.39	86.45	88.76	<u>94.06</u>	93.13	95.12	93.18
FPR	12.59	8.74	27.61	13.55	11.24	<u>5.94</u>	6.87	4.88	6.82
TPR (C2)	<u>98.49</u>	99.01	64.12	93.91	92.19	95.84	97.39	85.07	97.67
FNR	<u>1.51</u>	0.99	35.88	6.09	7.81	4.16	2.61	14.93	2.33
OA(%)	87.59	91.39	72.26	86.57	88.82	<u>94.09</u>	93.20	94.96	93.25
AA(%)	92.95	95.14	68.26	90.18	90.48	94.95	<u>95.26</u>	90.10	95.43

Önerilen yöntemlere ait sınıflandırma haritaları diğer yöntemlere ait sınıflandırma haritalarına kıyasla daha az yanlış pozitif örnek içermektedir ve yer gerçekliği görüntüsüne daha çok benzemektedir. Tablo 4.16 incelendiğinde de en yüksek AA değerlerine sahip olan yöntemler önerdiğimiz yöntemlerdir. Genel doğrulukta (OA) en iyi performansa sahip yöntem SBNSCMV yöntemi iken, en iyi ikinci performansa sahip yöntem WBNSC yöntemidir. Ortalama doğrulukta (AA) ise en iyi performansa sahip yöntem MSBNSC yöntemi iken, en iyi ikinci performansa sahip yöntem SBNSC yöntemidir. RJNSC C2 sınıfında (müsilağ) en iyi performansı göstermesine rağmen, C1 sınıfı için sınıflandırma doğruluğu düşüktür, çok fazla yanlış pozitif örnek içermektedir.

Diğer yandan Şekil 4.25'te görüldüğü üzere, süperpiksel tabanlı yöntemler de müsilağları pencere tabanlı yöntemlerde olduğu gibi ince bir çizgi halinde tespit edebilmektedir. Bunun nedeni, Bölüm 4.5.1.'de verildiği üzere, Bursa müsilağ verisi için süperpiksel tabanlı yöntemlere ait süperpiksel sayılarının çok büyük seçilmesi ve bu sayede süperpiksel boyutlarının küçük olmasıdır. İstanbul ve Bursa müsilağ veri kümelerinde AA anlamında en yüksek

performanslar önerilen MSBNSC yöntemi ile elde edilmiştir. Bunun en önemli sebebi bu yöntemde çok ölçekli süperpikseller kullanılması sayesinde sahne içerisinde yer alan farklı boyuttaki yapıların ve morfolojik özelliklerin bu ölçekler ile yakalanabilmesidir.


4.5.4. Bursa Veri Kümesinden Alınan Eğitim Verilerinin İstanbul Veri Kümesi Üzerinde Test Edilmesi

Bu bölümde Bursa müsilaaj veri kümesinden alınan eğitim verileri ile İstanbul müsilaaj veri kümesi üzerinde yöntemlerin sınıflandırma performansları incelenmiş ve Bölüm 4.5.2. ile karşılaştırılmış, farklı bir veri kümesinden eğitim verisi alınmasının yöntemlerin performansına etkisi analiz edilmiştir. Sınıf başına 20 eğitim örneği için elde edilen farklı yöntemlerin sınıflandırma haritaları Şekil 4.26'da verilmiş ve yöntemlerin her bir sınıf için ayrıntılı sınıflandırma performansları Tablo 4.17'de verilmiştir.

Tablo 4.17 Bursa veri kümesinden alınan eğitim verileri ile İstanbul veri kümesi üzerinde yapılan deneyler için önerilen yöntemlerin ve karşılaştırılan diğer yöntemlerin sınıflandırma doğrulukları (%)

Sınıf	JNSC	RJNSC	SVM-MV	RPN _{et}	SKCR	WBNSC	SBNSC	SBNSCMV	MSBNSC
TNR (C1)	91.03	<u>93.70</u>	73.03	78.99	88.24	91.54	91.07	95.74	93.64
FPR	8.97	<u>6.30</u>	26.97	21.01	11.76	8.46	8.93	4.26	6.36
TPR (C2)	91.38	91.29	51.53	99.56	50.62	97.73	96.96	94.44	<u>97.15</u>
FNR	8.62	8.71	48.47	0.44	49.38	2.27	3.04	5.56	<u>2.85</u>
OA(%)	91.03	93.69	72.96	79.06	88.12	91.56	91.09	95.74	<u>93.65</u>
AA(%)	91.21	92.50	62.28	89.28	69.43	94.63	94.02	<u>95.09</u>	95.50

Şekil 4.26 ve Şekil 4.24 karşılaştırıldığında SKCR ve RPN_{et} yöntemleri haricinde, ilgili koşu için tüm yöntemlere ait sınıflandırma haritalarının bu deneyde daha fazla yanlış pozitif örnek içerdiği görülmektedir. Özellikle SKCR yöntemine ait sınıflandırma haritasında yanlış pozitiflerde belirgin bir düşüş görülmektedir. Tablo 4.17 ile Tablo 4.15 karşılaştırıldığında da SKCR yönteminde FPR değeri düşerken diğer yöntemler için artış göstermektedir. SKCR yöntemi bu açıdan avantajlı gibi gözükse de müsilaaj tespiti konusunda kötü anlamda en çok etkilenen yöntemdir. Tablo 4.17 ile Tablo 4.15 karşılaştırıldığında da SKCR yöntemi için TPR değerinde belirgin bir düşüş olduğu görülmektedir. Diğer yöntemlerin performansı bu anlamda çok fazla etkilenmemiştir.



Şekil 4.26 Bursa veri kümesinden alınan eğitim verileri ile İstanbul veri kümesi üzerinde yapılan deneyler için önerilen yöntemler ve karşılaştırılan diğer yöntemler ile elde edilen sınıflandırma haritaları. Sınıf başına 20 örnek eğitim verisi olarak kullanılmış, geriye kalan örnekler test verisi olarak kullanılmıştır.


Tablo 4.17’de yer alan ortalama doğruluklar (AA) incelendiğinde SKCR ve SVM-MV yöntemlerinin performanslarında belirgin bir düşüş gözlenirken diğer yöntemlerin performansları yaklaşık olarak %1-4 bandında düşmüştür. En az düşüş gösteren yöntem önerilen SBNSCMV yöntemidir. Tüm yöntemler için FPR değeri artıyor iken SBNSCMV yöntemi için azalmaktadır ve C1 (deniz) sınıfı için en iyi performans bu yönteme aittir. SBNSCMV yönteminde kullanılan çoğunluk oylama aşaması FPR değerinin artışı engellemiştir. Diğer yandan, bu yöntem için TPR değeri %2 oranında düşmüştür. Ortalama doğrulukta (AA) en iyi performansa sahip yöntemler sırasıyla önerdiğimiz MSBNSC, SBNSCMV, WBNSC ve SBNSC yöntemleridir ve diğer yöntemler ile olan performans farkı Tablo 4.15’e göre daha da artmıştır. Şekil 4.26’da yer alan sınıflandırma haritalarına bakıldığında da yer-gerçekliği görüntüsüne en çok benzeyen yöntem MSBNSC yöntemidir.

4.5.5. İstanbul Veri Kümesinden Alınan Eğitim Verilerinin Bursa Veri Kümesi Üzerinde Test Edilmesi

Bu bölümde İstanbul müsilaaj veri kümesinden alınan eğitim verileri ile Bursa müsilaaj veri kümesi üzerinde yöntemlerin sınıflandırma performansları incelenmiş ve Bölüm 4.5.3. ile karşılaştırılmış, farklı bir veri kümesinden eğitim verisi alınmasının yöntemlerin performansına etkisi analiz edilmiştir. Sınıf başına 20 eğitim örneği için elde edilen farklı yöntemlerin sınıflandırma haritaları Şekil 4.27’de ve yöntemlerin her bir sınıf için ayrıntılı sınıflandırma performansları Tablo 4.18’de verilmiştir.

Tablo 4.18 İstanbul veri kümesinden alınan eğitim verileri ile Bursa veri kümesi üzerinde yapılan deneyler için önerilen yöntemlerin ve karşılaştırılan diğer yöntemlerin sınıflandırma doğrulukları (%)

Sınıf	JNSC	RJNSC	SVM-MV	RPNNet	SKCR	WBNSC	SBNSC	SBNSCMV	MSBNSC
TNR (C1)	64.37	62.95	90.48	91.13	68.45	71.86	71.20	72.49	71.15
FPR	35.63	37.05	9.52	8.87	31.55	28.14	28.80	27.51	28.85
TPR (C2)	97.82	99.31	28.15	76.43	81.46	80.83	91.02	70.69	91.54
FNR	2.18	0.69	71.85	23.57	18.54	19.17	8.98	29.31	8.46
OA(%)	64.91	63.54	89.47	90.89	68.66	72.00	71.52	72.46	71.48
AA(%)	81.10	81.13	59.32	83.78	74.96	76.35	81.11	71.59	81.35



Şekil 4.27 İstanbul veri kümesinden alınan eğitim verileri ile Bursa veri kümesi üzerinde yapılan deneyler için önerilen yöntemler ve karşılaştırılan diğer yöntemler ile elde edilen sınıflandırma haritaları. Sınıf başına 20 örnek eğitim verisi olarak kullanılmış, geriye kalan örnekler test verisi olarak kullanılmıştır.

Şekil 4.27 ve Şekil 4.25 karşılaştırıldığında, bu deneyde hemen hemen tüm yöntemlerde yanlış pozitif örnek sayısının belirgin bir şekilde arttığı görülmektedir. Şekil 4.27’de yer alan sınıflandırma haritalarında ilgili koşu için özellikle sahnenin sol üst ve sol alt kısmında çok fazla yanlış pozitif örneğin yer aldığı göze çarpmaktadır. Tablo 4.18 ile Tablo 4.16 karşılaştırıldığında da SVM-MV ve RpNet yöntemleri dışında tüm yöntemlerde FPR değerinde büyük artışların olduğu görülmektedir. SVM-MV ve RpNet yöntemleri bu açıdan avantajlıdır, Fakat, özellikle SVM-MV olmak üzere her iki yöntem de, Tablo 4.18 ile Tablo 4.16 karşılaştırıldığında, mülaj tespiti (TPR) konusunda kötü anlamda en çok etkilenen yöntemlerdir. İki tablo karşılaştırıldığında TPR değerleri açısından kötü anlamda etkilenen diğer yöntemler ise SBNMCMV ve WBNMCMV yöntemleridir. Mülaj tespitinde en az etkilenen yöntemler RJNSC ve JNSC yöntemleri olmasına rağmen, bu yöntemler ile elde edilen sonuçlarda yanlış pozitif örnek sayısı (FPR) çok fazla artmıştır.

Tablo 4.17’de yer alan ortalama doğruluklar (AA) incelendiğinde bu deneyde Bölüm 4.5.5.’e kıyasla daha belirgin (%10-20 bandında) düşüşler olmuştur. En az düşüş gösteren yöntem önerilen RpNet yöntemidir. Ortalama doğrulukta (AA) en iyi performansa sahip yöntem RpNet yöntemi iken bu yöntemi sırasıyla MSBNMCMV, RJNSC ve SBNMCMV yöntemleri izlemektedir.

4.5.6. Yöntemlerin Hesaplama Karmaşıklığının Analizi

Bu bölümde yöntemlerin hesaplama karmaşıklıkları Indian Pines ve İstanbul mülaj verileri üzerinde analiz edilmiştir. Deneyler, özellikleri 64 GB RAM ve 2,40 GHz ile Intel(R) Xeon(R) 3,2 GHz olan bir bilgisayar üzerinde ve MATLAB kullanılarak yapılmıştır. Bölüm 4.5.2. ve 4.3.3.’de kullanılan verilerin aynısı (sınıf başına 20 eğitim verisi) ile süre ölçümleri alınmıştır. Yöntemlerin ortalama yürütme süreleri Tablo 4.19’da verilmiştir.

Tablo 4.19 Indian Pines ve İstanbul mülaj veri kümeleri için yöntemlerin yürütme süreleri (saniye cinsinden)

Veri Kümesi	JNSC	RJNSC	SVM-MV	RpNet	SKCR	WBNMCMV	SBNMCMV	SBNMCMV	MSBNMCMV
Indian Pines	14.43	14.78	1.00	1.07	15.66	138.16	5.84	3.68	41.31
İstanbul Mülaj	81.22	79.94	2.17	2.76	14.54	267.51	13.48	11.58	57.72

Veri kümesinde yer alan örnek sayısı ve sınıf sayısı, bant sayısı, algoritmaların karmaşıklığı, pencere boyutu, süperpiksel sayısı gibi faktörler yöntemlerin çalışma sürelerini etkilemektedir. RPNet ve SVM-MV yöntemlerinde, MATLAB içerisinde LIBSVM [162] toolbox'ı kullanılarak C programlama dilinde yazılmış fonksiyonlar çağırılmaktadır, bu nedenle bu yöntemler hızlıdır. RPNet'in basit bir ağ mimarisine sahip olması da hız açısından avantaj sağlamaktadır. Bu yöntemlerden sonra önerilen SBNSCMV ve SBNSC yöntemleri sırasıyla en hızlı yöntemlerdir. SBNSCMV yöntemi içerisinde ekstra bir son aşama yer almasına rağmen SBNSC yönteminden hızlıdır. Bunun nedeni, bu yöntemler için seçilen süperpiksel sayısı parametresinin farklı seçilmesi ve hıza etki etmesidir. MSBNSC, çok ölçekli süperpikseller kullanması nedeniyle bu yöntemlere kıyasla daha yavaştır. Önerilen WBNSC yöntemi, sadece tek bir test pikseline etiket atamak için yüksek boyutlara sahip bir uzamsal pencerede çok sayıda piksel kullanılması nedeniyle zaman alıcıdır. WBNSC'nin aksine önerilen süperpiksel tabanlı yöntemde süperpiksel bazında sınıflandırma yapımları sayesinde WBNSC yöntemine kıyasla çok daha hızlıdır.

5. SONUÇLAR VE TARTIŞMA

Tez kapsamında HSG sınıflandırma için uzamsal bilgiden etkili bir şekilde yararlanan gösterim tabanlı bir yaklaşım önerilmiştir. Önerdiğimiz sınıflandırma yaklaşımı SSNSC, basitçe iki altuzay arasındaki yakınlığa bakarak sınıflandırma yapmaktadır. Önerdiğimiz sınıflandırma yaklaşımının basit ve anlamlı bir geometrik yorumu vardır. Önerdiğimiz sınıflandırma yaklaşımında sunulan optimizasyon problemini çözmek için CCA kullanılmaktadır ve CCA sayesinde kapalı-form bir çözüm elde edilmektedir ve bu sayede herhangi bir eğitim aşaması söz konusu değildir. Ayrıca sunulan optimizasyon probleminde ayarlanması gereken herhangi bir parametre de yoktur. Bu avantajları sayesinde önerilen yöntem basit ve uygulaması kolaydır. Bölüm 4.2.'de ayrıntılı olarak tartışıldığı üzere önerilen sınıflandırma yaklaşımı uzamsal bölge içerisinde yer alan gürültülü piksellere karşı dayanıklıdır. Fakat, uzamsal bölge içerisinde farklı sınıflara ait örneklerin olması durumunda yanlış sınıflandırmalar olabilmektedir. Komşuluk ilişkisine dayanarak varsayım yapılan bu tip yöntemlerde bu gibi yanlış sınıflandırılmalar kaçınılmazdır. Burada asıl üzerinde durulması gereken, uzamsal bilgi olarak homojen bölgelerin elde edilmesidir.

Tez kapsamında sunulan bu sınıflandırma yaklaşımı kullanılarak dört farklı yöntem geliştirilmiştir. Yapılan deneyler, sınırlı eğitim verisi olması durumunda geliştirilen yöntemlerin karşılaştırılan literatürdeki diğer yöntemlere kıyasla daha başarılı olduğunu göstermektedir. HSG işleme alanında veri toplama ve etiketleme işlemi zaman alıcı ve maliyetlidir, bu yüzden eğitim verisi sayısı bu alanda sınırlıdır. Bu göz önüne alındığında, geliştirilen yöntemler ile sınırlı eğitim verisi olduğu durumda elde edilen bu başarılı sonuçlar daha da anlam kazanmaktadır.

Önerilen SSNSC sınıflandırma yaklaşımına girdi olarak eğitim verisi ve uzamsal bilgiden yararlanırken kullanılan pikseller verilmektedir. Önerilen yöntemlerin ilkinde (WBNSC), SSNSC'ye uzamsal bilgi girdisi olarak test pikselinin komşuluğunda bir pencere içerisinde yer alan pikseller verilirken, önerilen diğer üç yöntemde (SBNSC, MSBNSC ve SBNSCMV), SSNSC'ye uzamsal bilgi girdisi olarak süperpiksel içerisindeki pikseller

verilmektedir. Önerilen yöntemler arasındaki diğer bir farklılık ise SSNSC ile elde edilen etiket kestirimi WBNSC yönteminde sadece bir test pikseline atanırken SBNSC yönteminde süperpiksel içerisindeki tüm piksellere atanmasıdır. Önerilen süperpiksel tabanlı yöntemler piksel bazında sınıflandırma yapmak yerine süperpiksel bazında sınıflandırma yapmaktadır. Önerilen her yöntemin birbirlerine karşı üstünlükleri ve zaafları bulunmaktadır. Önerilen yöntemlerin performansı görüntü içerisindeki sınıfların boyutuna, yapısına, birbirlerine olan yakınlıklarına doğrudan bağlıdır ve bahsedilen farklı koşullar için bu yöntemler birbirleri yerine tercih edilebilir.

Önerilen WBNSC yönteminin avantajı, bu yöntemde uzamsal bilgidен yararlanılması sürecinde ek bir ön işleme ve son işleme aşamasının olmamasıdır. Bu yöntemin diğer bir avantajı ise bu yöntemde ayarlanması gereken tek bir parametrenin (pencere boyutu) olması ve bu parametrenin Bölüm 4.3.1.'de bahsedildiği gibi görüntü hakkında edinilen bazı ön bilgiler sayesinde kolayca ayarlanabilmesidir. Bahsedilen avantajları sayesinde WBNSC yöntemi basit ve uygulaması kolay bir yöntemdir. Ayrıca, WBNSC yöntemi gürültülü piksellerle ve arkaplan piksellerine karşı dayanıklı olması nedeniyle Bölüm 4.3.4.'te de gözlemlendiği gibi Botswana veri kümesi gibi birbirine yakın sınıfların olmadığı sahnelerde etkilidir. Fakat, sahne içerisindeki sınıflar birbirine yakın ise, uzamsal bilgidен yararlanmak için sabit pencere kullanımı sınıf sınırlarında yanlış sınıflandırmalara neden olabilmektedir ve bu, WBNSC yönteminin performansını olumsuz yönde etkilemektedir. Indian Pines veri kümesi de bu tip bir veri kümesidir. Bu nedenle, Indian Pines veri kümesinde WBNSC yönteminin performansı diğer yöntemlere göre daha düşüktür. WBNSC yönteminin bir diğer dezavantajı, tek bir test pikseline etiket atayabilmek için test pikselinin komşuluğunda bir pencere içerisinde yer alan tüm piksellerin kullanılmasıdır. Hiperspektral görüntülerin büyük boyutlu (bant sayısı fazla) olduğu göz önüne alındığında sadece bir pikseli sınıflandırmak için bu denli büyük verilerin hesaplama sırasında kullanılması beraberinde büyük bir hesap ve zaman maliyeti getirmektedir. Bölüm 4.3.6.'da verilen yürütme sürelerinde önerilen yöntemin, karşılaştırılan yöntemlere göre daha yavaş kalmasının nedenlerinden biri de budur. Hız kısıtı olmadığı durumda bu yöntem basitliği nedeniyle tercih edilebilir.

WBNSC yönteminin bu bahsedilen problemleriyle başa çıkmak için tez kapsamında

süperpiksel tabanlı yöntemler önerilmiştir. Bölüm 4.4.2.'de önerilen tüm yöntemler kıyaslanmıştır. Bu kısımda önerilen SBSNC yönteminde çıkarılan süperpiksellerin genelde homojen olduğu görülmektedir ve çıkarılan süperpikseller ile sınıf sınırlarının düzgün bir şekilde bulunabildiği görülmektedir. Böylece önerilen SBSNC ve diğer önerilen süperpiksel tabanlı yöntemlerde, WBNSC yönteminde karşılaşılan sınıf sınırlarındaki yanlış sınıflandırma problemi giderilmektedir. Bahsedilen avantajları nedeniyle SBSNC yönteminin performansı Bölüm 4.4.3. ve Bölüm 4.4.4.'te yapılan deneylerde WBNSC'ye göre daha yüksektir. Ayrıca önerilen süperpiksel tabanlı yöntemlerde süperpiksel bazında sınıflandırma yapılması hız açısından önemli bir avantaj sağlamaktadır. Bölüm 4.5.6.'da verilen yöntemlere ait yürütme süreleri incelendiğinde önerilen süperpiksel tabanlı yöntemlerin hızının diğer yöntemlerle yarışır bir seviyede olduğu görülmektedir.

SBSNC yönteminin bazı dezavantajları da vardır. Her ne kadar süperpiksellerin homojen olması beklense de süperpikseller bazı durumlarda farklı sınıflara ait örnekleri de içerebilmektedir ve karışım halinde olabilmektedir. Bununla birlikte, farklı sınıfa ait eğitim verileri arasındaki benzerliğin yüksek olduğu durumlarda ya da süperpiksellerin tamamının gürültülü piksellerden oluştuğu durumlarda, bir süperpiksel doğru sınıfa atanmak yerine diğer bir sınıfa atanabilir. Bölüm 4.4.2.'de, bahsedilen senaryolar için örnekler verilmiştir. Bu tarz durumlar için etiketlenecek süperpikselin komşuluğundaki süperpiksellerin etiketlerinden de yararlanan SBSNCMV yöntemi tercih edilebilir. Salinas veri kümesi bu bahsedilen durumları içeren bir veri kümesidir ve Bölüm 4.4.3.'te görüldüğü gibi bu veri kümesinde en yüksek başarıma sahip olan yöntem SBSNCMV yöntemidir.

Bölüm 4.4.2.'de süperpiksel boyutunun sınıflandırmaya olan etkisi incelenmiştir. Bu kısımda yapılan deneylere bakıldığında süperpiksellerin boyutu büyük olduğunda bir süperpiksel içerisinde farklı sınıflara ait piksellerin olma ihtimali artmaktadır, bu da yanlış sınıflandırılmış büyük alanların olmasına yol açmaktadır. Süperpiksellerin boyutunun küçük olması durumunda uzamsal açıdan yeterli bilgi sağlanamamaktadır. Görüntülerde yer alan sınıflar farklı boyutlarda ve morfolojik yapıdadır. Bu farklılıkları tek bir süperpiksel ölçeği ile yakalamak zor olabilmektedir. SBSNC yönteminin bir diğer dezavantajı da sınıflandırma sırasında tek bir ölçek ile elde edilen süperpikseller ile sınıflandırma yapmasıdır. Görüntü

içerisindeki farklı boyut ve morfolojik yapılardaki sınıfları daha iyi yakalayabilmek için MSBNSC yöntemi önerilmiştir. Bölüm 4.4.4.'te kullanılan Indian Pines veri kümesi ve Bölüm 4.5.2. ve 4.5.3.'teki müsilaj veri kümeleri de bahsedilen tipte veri kümeleri olması nedeniyle, bu bölümlerde yapılan deneylerde en yüksek başarıma sahip olan yöntem MSBNSC yöntemidir. Bu tür sahneler için çok ölçekli süperpiksel kullanan MSBNSC yöntemi tercih edilebilir. MSBNSC yöntemi bahsedilen şartlarda avantaj sağlasa da çoklu ölçek kullanması nedeniyle Bölüm 4.5.6.'da elde edilen yürütme sürelerine bakıldığında SBNSC yöntemine göre zamansal ve hesapsal anlamda daha maliyetlidir. Bahsedilen avantajlarının aksine, süperpiksel tabanlı yöntemlerde parametre ayarlama, pencere tabanlı yöntemlerde olduğu kadar kolay değildir. Süperpiksel sayısının belirlenmesi pencere kullanılan versiyondaki pencere boyutunun belirlenmesine göre daha zordur. Ayrıca süperpiksel tabanlı yöntemlerin performansı süperpiksel çıkarma yöntemlerinin performansına çok bağlıdır. Önerilen yöntemler bahsedildiği üzere farklı amaçlara hizmet etmektedir.

Önerilen sınıflandırma yaklaşımı jenerik bir sınıflandırma yaklaşımıdır ve uzamsal bilgilerden farklı şekillerde yararlanılarak HSG alanında çeşitli yöntemler geliştirilebilir. SSNSC yaklaşımı farklı araştırma alanlarında da kullanılabilir. Önerilen sınıflandırma yaklaşımı HSG sınıflandırma probleminde karşılaşılan bir çok zorlukla başa çıkabilmektedir, fakat sınıf içi örnekler içerisindeki spektral değişkenlik ve sınıflar-arası örnekler arasındaki spektral benzerlik olduğu durumda önerilen yaklaşımın performansı olumsuz yönde etkilenebilir. Bununla başa çıkmak için, ilerleyen çalışmalarda eğitim verilerini en iyi temsil eden alt bir küme seçilerek performans iyileştirmesi yapılabilir. Bu işlem, hız açısından da avantaj sağlayacaktır.

6. KAYNAKLAR

- [1] J. R. Schott. *Remote sensing: the image chain approach*. Oxford University Press on Demand, **2007**.
- [2] D. G. Manolakis, R. B. Lockwood, and T. W. Cooley. *Hyperspectral Imaging Remote Sensing: Physics, Sensors, and Algorithms*. Cambridge University Press, **2016**. 10.1017/CBO9781316017876.
- [3] M. T. Eismann. *Hyperspectral remote sensing*. SPIE Press monograph ; PM210. SPIE, Bellingham, Wash., **2012**. ISBN 0-8194-8787-2.
- [4] H. Madani. *Hyperspectral Image Classification for Remote Sensing*. Ph.D. thesis, Electronic Thesis and Dissertation Repository. 6940, **2020**.
- [5] N. Mehta, S. Shaik, R. Devireddy, and M. R. Gartia. Single-cell analysis using hyperspectral imaging modalities. *Journal of biomechanical engineering*, 140 2, **2018**.
- [6] H. Freij. *Hyperspectral Image Registration and Construction From Irregularly Sampled Data*. Master's thesis, Linköping University, Computer Vision, **2021**.
- [7] J. Benediktsson and P. Ghamisi. *Spectral-Spatial Classification of Hyperspectral Remote Sensing Images*. **2015**.
- [8] P. Ghamisi, J. Plaza, Y. Chen, J. Li, and A. J. Plaza. Advanced spectral classifiers for hyperspectral images: A review. *IEEE Geoscience and Remote Sensing Magazine*, 5(1):8–32, **2017**. ISSN 2373-7468.
- [9] L. Ma, M. Crawford, and J. Tian. Local manifold learning-based k -nearest-neighbor for hyperspectral image classification. *Geoscience and Remote Sensing, IEEE Transactions on*, 48(11), **2010**. ISSN 0196-2892. 10.1109/TGRS.2010.2055876.

- [10] H. Irmak, G. B. Akar, and S. E. Yuksel. A MAP-based approach for hyperspectral imagery super-resolution. *IEEE Transactions on Image Processing*, 27(6):2942–2951, **2018**.
- [11] S. Yuksel, T. Dubroca, R. Hummel, and P. Gader. Differential reflection spectroscopy: A novel method for explosive detection. *Acta Physica Polonica A*, 123(2):263–264, **2013**.
- [12] I. C. C. Acosta, M. Khodadadzadeh, L. Tusa, P. Ghamisi, and R. Gloaguen. A machine learning framework for drill-core mineral mapping using hyperspectral and high-resolution mineralogical data fusion. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12(12):4829–4842, **2019**.
- [13] G. K. Devi, B. Ganasri, and G. Dwarakish. Applications of remote sensing in satellite oceanography: A review. *Aquatic Procedia*, 4:579–584, **2015**. ISSN 2214-241X. International Conference on Water Resources, Coastal and Ocean Engineering (ICWRCOE’15).
- [14] Y. Liu, H. Pu, and D.-W. Sun. Hyperspectral imaging technique for evaluating food quality and safety during various processes: A review of recent applications. *Trends in Food Science & Technology*, 69:25–35, **2017**. ISSN 0924-2244.
- [15] C. Chang. *Hyperspectral Imaging: Techniques for Spectral Detection and Classification*. Number 1. c. in *Hyperspectral Imaging: Techniques for Spectral Detection and Classification*. Springer US, **2003**. ISBN 9780306474835.
- [16] H. Grahn and P. Geladi. *Techniques and Applications of Hyperspectral Image Analysis*. Wiley, **2007**. ISBN 9780470010877.
- [17] 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*, 5(2):354–379, **2012**. ISSN 1939-1404. 10.1109/JSTARS.2012.2194696.

- [18] N. Keshava and J. F. Mustard. Spectral unmixing. *IEEE Signal Processing Magazine*, 19(1):44–57, **2002**.
- [19] K. G. Toker and S. E. Yüksel. A greedy algorithm for sparse unmixing. In *2018 26th Signal Processing and Communications Applications Conference (SIU)*, pages 1–4. **2018**. 10.1109/SIU.2018.8404796.
- [20] D. Manolakis, D. Marden, and G. Shaw. Hyperspectral image processing for automatic target detection applications. *Lincoln Lab J*, 14, **2003**.
- [21] M. A. Toksöz, K. G. Toker, and G. G. Güngör. An automatic dictionary construction framework for sparsity-based hyperspectral target detectors. *IEEE Geoscience and Remote Sensing Letters*, 15(8):1264–1268, **2018**. 10.1109/LGRS.2018.2835759.
- [22] S. E. Yuksel, M. Oturak, and K. G. Toker. Transfer learning on GPR data for IED detection in various environments. In G. W. Kamerman and O. Steinvall, editors, *Electro-Optical Remote Sensing XIII*, volume 11160, page 111600F. International Society for Optics and Photonics, SPIE, **2019**. 10.1117/12.2532491.
- [23] S. Liu, D. Marinelli, L. Bruzzone, and F. Bovolo. A review of change detection in multitemporal hyperspectral images: Current techniques, applications, and challenges. *IEEE Geoscience and Remote Sensing Magazine*, 7(2):140–158, **2019**. 10.1109/MGRS.2019.2898520.
- [24] G. Mercier and M. Lennon. Support vector machines for hyperspectral image classification with spectral-based kernels. In *IGARSS 2003. 2003 IEEE International Geoscience and Remote Sensing Symposium. Proceedings (IEEE Cat. No. 03CH37477)*, volume 1, pages 288–290. IEEE, **2003**.
- [25] P. Ghamisi, J. Plaza, Y. Chen, J. Li, and A. Plaza. Advanced spectral classifiers for hyperspectral images: A review. *IEEE Geoscience and Remote Sensing Magazine (GRSM)*, 5, **2017**. 10.1109/MGRS.2016.2616418.

- [26] A. Davari, E. Aptoula, B. Yanikoglu, A. Maier, and C. Riess. GMM-based synthetic samples for classification of hyperspectral images with limited training data. *IEEE Geoscience and Remote Sensing Letters*, 15(6):942–946, **2018**.
- [27] A. Koz. Ground-based hyperspectral image surveillance systems for explosive detection: Part i—state of the art and challenges. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12(12):4746–4753, **2019**.
- [28] S. Jia, Z. Ji, Y. Qian, and L. Shen. Unsupervised band selection for hyperspectral imagery classification without manual band removal. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5(2):531–543, **2012**. 10.1109/JSTARS.2012.2187434.
- [29] A. Agarwal, T. El-Ghazawi, H. El-Askary, and J. Le-Moigne. Efficient hierarchical-pca dimension reduction for hyperspectral imagery. In *2007 IEEE International Symposium on Signal Processing and Information Technology*, pages 353–356. **2007**. 10.1109/ISSPIT.2007.4458191.
- [30] J. Harsanyi and C.-I. Chang. Hyperspectral image classification and dimensionality reduction: an orthogonal subspace projection approach. *IEEE Transactions on Geoscience and Remote Sensing*, 32(4):779–785, **1994**. 10.1109/36.298007.
- [31] P. Ghamisi, E. Maggiori, S. Li, R. Souza, Y. Tarablaka, G. Moser, A. De Giorgi, L. Fang, Y. Chen, M. Chi, S. B. Serpico, and J. A. Benediktsson. New frontiers in spectral-spatial hyperspectral image classification: The latest advances based on mathematical morphology, Markov random fields, segmentation, sparse representation, and deep learning. *IEEE Geoscience and Remote Sensing Magazine*, 6(3):10–43, **2018**. 10.1109/MGRS.2018.2854840.
- [32] E. Soyak. *Hyperspectral data classification via capsule networks*. Master’s thesis, Middle East Technical University, **2019**.

- [33] 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*, 54(10):6232–6251, **2016**. 10.1109/TGRS.2016.2584107.
- [34] H. Lee and H. Kwon. Going deeper with contextual cnn for hyperspectral image classification. *IEEE Transactions on Image Processing*, 26:1–1, **2017**. 10.1109/TIP.2017.2725580.
- [35] S. E. Yuksel, S. Kucuk, and P. D. Gader. SPICEE: An extension of SPICE for sparse endmember estimation in hyperspectral imagery. *IEEE Geoscience and Remote Sensing Letters*, 13(12):1910–1914, **2016**.
- [36] B. Pan, Z. Shi, and X. Xu. Multiobjective-based sparse representation classifier for hyperspectral imagery using limited samples. *IEEE Transactions on Geoscience and Remote Sensing*, 57(1):239–249, **2019**. ISSN 1558-0644.
- [37] S. Cai, Q. Du, and R. J. Moorhead. Hyperspectral imagery visualization using double layers. *IEEE Transactions on Geoscience and Remote Sensing*, 45(10):3028–3036, **2007**. 10.1109/TGRS.2007.894922.
- [38] P. Ghamisi and J. A. Benediktsson. Feature selection based on hybridization of genetic algorithm and particle swarm optimization. *IEEE Geoscience and Remote Sensing Letters*, 12(2):309–313, **2015**. 10.1109/LGRS.2014.2337320.
- [39] P. Ghamisi, A.-R. Ali, M. Couceiro, and J. Benediktsson. A novel evolutionary swarm fuzzy clustering approach for hyperspectral imagery. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8:1–10, **2015**. 10.1109/JSTARS.2015.2398835.
- [40] A. Jain, R. Duin, and J. Mao. Statistical pattern recognition: a review. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 22(1):4–37, **2000**. 10.1109/34.824819.

- [41] B. Waske and J. A. Benediktsson. *Pattern Recognition and Classification*, pages 503–509. Springer New York, New York, NY, **2014**. ISBN 978-0-387-36699-9. 10.1007/978-0-387-36699-9_69.
- [42] J. B. MacQueen. Some methods for classification and analysis of multivariate observations. In L. M. L. Cam and J. Neyman, editors, *Proc. of the fifth Berkeley Symposium on Mathematical Statistics and Probability*, volume 1, pages 281–297. University of California Press, **1967**.
- [43] J. C. Bezdek, R. Ehrlich, and W. Full. Fcm: The fuzzy c-means clustering algorithm. *Computers & Geosciences*, 10(2):191–203, **1984**. ISSN 0098-3004. [https://doi.org/10.1016/0098-3004\(84\)90020-7](https://doi.org/10.1016/0098-3004(84)90020-7).
- [44] G. Ball and D. Hall. *Isodata, a Novel Method of Data Analysis and Pattern Classification*. Architectural design. Stanford Research Institute, **1965**.
- [45] W. Wang, Y. Zhang, Y. Li, and X. Zhang. The global fuzzy c-means clustering algorithm. In *2006 6th World Congress on Intelligent Control and Automation*, volume 1, pages 3604–3607. **2006**. 10.1109/WCICA.2006.1713041.
- [46] Q. Jackson and D. Landgrebe. Adaptive Bayesian contextual classification based on Markov random fields. *IEEE Transactions on Geoscience and Remote Sensing*, 40(11):2454–2463, **2002**. 10.1109/TGRS.2002.805087.
- [47] B. Shahshahani and D. Landgrebe. The effect of unlabeled samples in reducing the small sample size problem and mitigating the Hughes phenomenon. *IEEE Transactions on Geoscience and Remote Sensing*, 32(5):1087–1095, **1994**. 10.1109/36.312897.
- [48] B. E. Boser, I. Guyon, and V. N. Vapnik. A training algorithm for optimal margin classifiers. In *COLT '92*. **1992**.
- [49] A. G. Gualtieri, S. Chettri, R. F. Crompt, and L. F. Johnson. Support vector machine classifiers as applied to AVIRIS data. **1999**.

- [50] C. M. Bishop. *Pattern Recognition and Machine Learning (Information Science and Statistics)*. Springer-Verlag, Berlin, Heidelberg, **2006**. ISBN 0387310738.
- [51] E. Merényi, W. Farrand, J. Taranik, and T. Minor. Classification of hyperspectral imagery with neural networks: Comparison to conventional tools. *Journal on Advances in Signal Processing*, 2014, **2014**. 10.1186/1687-6180-2014-71.
- [52] Y. Zhong and L. Zhang. An adaptive artificial immune network for supervised classification of multi-/hyperspectral remote sensing imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 50(3):894–909, **2012**. 10.1109/TGRS.2011.2162589.
- [53] S. A. Dudani. The distance-weighted k-nearest-neighbor rule. *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-6(4):325–327, **1976**. 10.1109/TSMC.1976.5408784.
- [54] P. Cunningham and S. Delany. k-nearest neighbour classifiers. *Mult Classif Syst*, 54, **2007**. 10.1145/3459665.
- [55] C. Bo, H. Lu, and D. Wang. Spectral-spatial k-nearest neighbor approach for hyperspectral image classification. *Multimedia Tools and Applications*, 77(9):10419–10436, **2018**.
- [56] J. Ham, Y. Chen, M. Crawford, and J. Ghosh. Investigation of the random forest framework for classification of hyperspectral data. *IEEE Transactions on Geoscience and Remote Sensing*, 43(3):492–501, **2005**. 10.1109/TGRS.2004.842481.
- [57] B. Waske, J. Benediktsson, and J. Sveinsson. Random forest classification of remote sensing data. *Signal and Image Processing for Remote Sensing*, pages 365–374, **2012**. 10.1201/b11656-21.
- [58] S. Lawrence, C. L. Giles, A. C. Tsoi, and A. D. Back. Face recognition: A convolutional neural-network approach. *IEEE transactions on neural networks*, 8(1):98–113, **1997**.

- [59] N. Kalchbrenner, E. Grefenstette, and P. Blunsom. A convolutional neural network for modelling sentences. *arXiv preprint arXiv:1404.2188*, **2014**.
- [60] P. Sermanet, S. Chintala, and Y. LeCun. Convolutional neural networks applied to house numbers digit classification. In *Pattern Recognition (ICPR), 2012 21st International Conference on*, pages 3288–3291. IEEE, **2012**.
- [61] D. C. Ciresan, U. Meier, L. M. Gambardella, and J. Schmidhuber. Convolutional neural network committees for handwritten character classification. In *Document Analysis and Recognition (ICDAR), 2011 International Conference on*, pages 1135–1139. IEEE, **2011**.
- [62] 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*, 7(6):2094–2107, **2014**. 10.1109/JSTARS.2014.2329330.
- [63] N. Audebert, B. Le Saux, and S. Lefevre. Deep learning for classification of hyperspectral data: A comparative review. *IEEE Geoscience and Remote Sensing Magazine*, 7(2):159–173, **2019**.
- [64] M. Paoletti, J. Haut, J. Plaza, and A. Plaza. Deep learning classifiers for hyperspectral imaging: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 158:279–317, **2019**. ISSN 0924-2716.
- [65] L. Zhang, M. Yang, and X. Feng. Sparse representation or collaborative representation: Which helps face recognition? volume 2011, pages 471–478. **2011**. 10.1109/ICCV.2011.6126277.
- [66] Y. Chen, N. M. Nasrabadi, and T. D. Tran. Hyperspectral image classification using dictionary-based sparse representation. *IEEE Transactions on Geoscience and Remote Sensing*, 49(10):3973–3985, **2011**.

- [67] L. Zhang, W.-D. Zhou, and B. Liu. Nonlinear nearest subspace classifier. In B.-L. Lu, L. Zhang, and J. Kwok, editors, *Neural Information Processing*, pages 638–645. Springer Berlin Heidelberg, Berlin, Heidelberg, **2011**. ISBN 978-3-642-24958-7.
- [68] W. Li, E. W. Tramel, S. Prasad, and J. E. Fowler. Nearest regularized subspace for hyperspectral classification. *IEEE Transactions on Geoscience and Remote Sensing*, 52(1):477–489, **2014**.
- [69] W. Li and Q. Du. Gabor-filtering-based nearest regularized subspace for hyperspectral image classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(4):1012–1022, **2014**.
- [70] M. Imani and H. Ghassemian. An overview on spectral and spatial information fusion for hyperspectral image classification: Current trends and challenges. *Information Fusion*, 59:59–83, **2020**. ISSN 1566-2535.
- [71] L. Zhang, Q. Zhang, B. Du, X. Huang, Y. Y. Tang, and D. Tao. Simultaneous spectral-spatial feature selection and extraction for hyperspectral images. *IEEE Transactions on Cybernetics*, 48(1):16–28, **2018**. 10.1109/TCYB.2016.2605044.
- [72] L. He, J. Li, C. Liu, and S. Li. Recent advances on spectral–spatial hyperspectral image classification: An overview and new guidelines. *IEEE Transactions on Geoscience and Remote Sensing*, 56(3):1579–1597, **2018**. 10.1109/TGRS.2017.2765364.
- [73] C. Bo, H. Lu, and D. Wang. Spectral-spatial K-nearest neighbor approach for hyperspectral image classification. *Multim. Tools Appl.*, 77(9):10419–10436, **2018**. 10.1007/s11042-017-4403-9.
- [74] X. Kang, S. Li, and J. Benediktsson. Spectralspatial hyperspectral image classification with edge-preserving filtering. *IEEE Transactions on Geoscience and Remote Sensing*, 52, **2014**. 10.1109/TGRS.2013.2264508.

- [75] J. Yue, S. Mao, and M. Li. A deep learning framework for hyperspectral image classification using spatial pyramid pooling. *Remote Sensing Letters*, 7:875–884, **2016**. 10.1080/2150704X.2016.1193793.
- [76] Y. Guo, X. Yin, X. Zhao, D. Yang, and Y. Bai. Hyperspectral image classification with svm and guided filter. *EURASIP Journal on Wireless Communications and Networking*, 2019, **2019**. 10.1186/s13638-019-1346-z.
- [77] Y. Chen, L. Zhu, P. Ghamisi, X. Jia, G. Li, and L. Tang. Hyperspectral images classification with gabor filtering and convolutional neural network. *IEEE Geoscience and Remote Sensing Letters*, 14(12):2355–2359, **2017**. 10.1109/LGRS.2017.2764915.
- [78] C. Bo, H. Lu, and D. Wang. Robust joint nearest subspace for hyperspectral image classification. *Remote Sensing Letters*, 7(10):915–924, **2016**.
- [79] S. Subudhi, R. N. Patro, P. K. Biswal, and F. Dell’Acqua. A survey on superpixel segmentation as a preprocessing step in hyperspectral image analysis. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14:5015–5035, **2021**. 10.1109/JSTARS.2021.3076005.
- [80] S. Zhang, S. Li, W. Fu, and L. Fang. Multiscale superpixel-based sparse representation for hyperspectral image classification. *Remote Sensing*, 9(2), **2017**. ISSN 2072-4292. 10.3390/rs9020139.
- [81] Y. Zhang and Y. Chen. Multiscale weighted adjacent superpixel-based composite kernel for hyperspectral image classification. *Remote Sensing*, 13:820, **2021**. 10.3390/rs13040820.
- [82] S. Li, L. Ni, X. Jia, L. Gao, B. Zhang, and M. Peng. Multi-scale superpixel spectral–spatial classification of hyperspectral images. *International Journal of Remote Sensing*, 37(20):4905–4922, **2016**. 10.1080/01431161.2016.1225175.

- [83] X. Yang, M. Zhao, T. Gao, J. Chen, and J. Zhang. Multiscale-superpixel-based sparseccm for hyperspectral target detection. *IEEE Geoscience and Remote Sensing Letters*, 19:1–5, **2022**. 10.1109/LGRS.2021.3079445.
- [84] A. Tuzcu Kokal, N. Olgun, and N. Musaoglu. Detection of mucilage phenomenon in the sea of marmara by using multi-scale satellite data. *Environmental Monitoring and Assessment*, **2022**. 10.1007/s10661-022-10267-6.
- [85] U. Karadurmuş and M. Sari. Marine mucilage in the sea of marmara and its effects on the marine ecosystem: Mass deaths. *Turkish Journal of Zoology*, 46:93–102, **2022**. 10.3906/zoo-2108-14.
- [86] G. Fogg. Some speculations on the nature of the pelagic mucilage community of the northern adriatic sea. *Science of The Total Environment*, 165(1):59–63, **1995**. ISSN 0048-9697. [https://doi.org/10.1016/0048-9697\(95\)04543-A](https://doi.org/10.1016/0048-9697(95)04543-A). Marine Mucilages.
- [87] B. Abaci, M. Dede, S. E. Yuksel, and M. Yilmaz. Mucilage detection from hyperspectral and multispectral satellite data. In *Algorithms, Technologies, and Applications for Multispectral and Hyperspectral Imaging XXVIII*, volume 12094, pages 151 – 158. SPIE, **2022**. 10.1117/12.2622287.
- [88] P. Ghamisi, J. A. Benediktsson, and M. O. Ulfarsson. Spectral–spatial classification of hyperspectral images based on hidden Markov random fields. *IEEE Transactions on Geoscience and Remote Sensing*, 52(5):2565–2574, **2014**. 10.1109/TGRS.2013.2263282.
- [89] 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*, 31(2):210–227, **2009**. ISSN 1939-3539.
- [90] Y. Tang, X. Li, Y. Xu, Y. Liu, J. Wang, C. Liu, and S. Liu. Hyperspectral image classification using sparse representation-based classifier. In *2014 IEEE Geoscience and Remote Sensing Symposium*, pages 3450–3453. **2014**.

- [91] T. Guha and R. K. Ward. Learning sparse representations for human action recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 34(8):1576–1588, **2012**.
- [92] G. Dong, G. Kuang, N. Wang, L. Zhao, and J. Lu. SAR target recognition via joint sparse representation of monogenic signal. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8(7):3316–3328, **2015**.
- [93] V. Pappyan, Y. Romano, J. Sulam, and M. Elad. Theoretical foundations of deep learning via sparse representations: A multilayer sparse model and its connection to convolutional neural networks. *IEEE Signal Processing Magazine*, 35(4):72–89, **2018**. 10.1109/MSP.2018.2820224.
- [94] J. A. Tropp and A. C. Gilbert. Signal recovery from random measurements via orthogonal matching pursuit. *IEEE Transactions on Information Theory*, 53(12):4655–4666, **2007**.
- [95] W. Dai and O. Milenkovic. Subspace pursuit for compressive sensing signal reconstruction. *IEEE Transactions on Information Theory*, 55(5):2230–2249, **2009**. 10.1109/TIT.2009.2016006.
- [96] S. S. Chen, D. L. Donoho, and M. A. Saunders. Atomic decomposition by basis pursuit. *SIAM Journal on Scientific Computing*, 20(1):33–61, **1998**. 10.1137/S1064827596304010.
- [97] R. Tibshirani. Regression shrinkage and selection via the lasso. *Journal of the Royal Statistical Society. Series B (Methodological)*, 58(1):267–288, **1996**. ISSN 00359246.
- [98] W. Li and Q. Du. A survey on representation-based classification and detection in hyperspectral remote sensing imagery. *Pattern Recognition Letters*, 83:115 – 123, **2016**. ISSN 0167-8655. Advances in Pattern Recognition in Remote Sensing.

- [99] W. Li, Y. Zhang, N. Liu, Q. Du, and R. Tao. Structure-aware collaborative representation for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, PP:1–16, **2019**. 10.1109/TGRS.2019.2912507.
- [100] W. Li and Q. Du. Joint within-class collaborative representation for hyperspectral image classification. *Selected Topics in Applied Earth Observations and Remote Sensing, IEEE Journal of*, 7:2200–2208, **2014**. 10.1109/JSTARS.2014.2306956.
- [101] T. Shu, B. Zhang, and Y. Y. Tang. Multi-view classification via a fast and effective multi-view nearest-subspace classifier. *IEEE Access*, 7:49669–49679, **2019**.
- [102] M. Xiong, F. Zhang, Q. Ran, W. Hu, and W. Li. Representation-based classifications with Markov random field model for hyperspectral urban data. *Journal of Applied Remote Sensing*, 8(1):1 – 12, **2014**.
- [103] D. Wang, H. Lu, and M. Yang. Least soft-threshold squares tracking. In *2013 IEEE Conference on Computer Vision and Pattern Recognition*, pages 2371–2378. **2013**.
- [104] K. Sharma and R. Rameshan. Image set classification using a distance-based kernel over affine grassmann manifold. *IEEE Transactions on Neural Networks and Learning Systems*, 32(3):1082–1095, **2021**. 10.1109/TNNLS.2020.2980059.
- [105] K. Ye and L.-H. Lim. Schubert varieties and distances between subspaces of different dimensions. *SIAM Journal on Matrix Analysis and Applications*, 37(3):1176–1197, **2016**. 10.1137/15M1054201.
- [106] G. Andrew, R. Arora, J. Bilmes, and K. Livescu. Deep canonical correlation analysis. In S. Dasgupta and D. McAllester, editors, *Proceedings of the 30th International Conference on Machine Learning*, volume 28 of *Proceedings of*

Machine Learning Research, pages 1247–1255. PMLR, Atlanta, Georgia, USA, **2013**.

- [107] H. Hotelling. *Relations Between Two Sets of Variates*, pages 162–190. Springer New York, New York, NY, **1992**. ISBN 978-1-4612-4380-9. 10.1007/978-1-4612-4380-9_14.
- [108] J. F. Hair, R. L. Tatham, R. E. Anderson, and W. Black. *Multivariate Data Analysis (5th Edition)*. Prentice Hall, 5th edition, **1998**. ISBN 0138948585.
- [109] K. Yang and J. Trewn. *Multivariate Statistical Methods in Quality Management*. McGraw-Hill engineering reference. McGraw-Hill Education, **2004**. ISBN 9780071432085.
- [110] W. Zheng, X. Zhou, C. Zou, and L. Zhao. Facial expression recognition using kernel canonical correlation analysis (kcca). *IEEE Transactions on Neural Networks*, 17(1):233–238, **2006**. ISSN 1045-9227.
- [111] F. Yan and K. Mikolajczyk. Deep correlation for matching images and text. In *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 3441–3450. **2015**. ISSN 1063-6919.
- [112] M. E. Sargin, Y. Yemez, E. Erzin, and A. M. Tekalp. Audiovisual synchronization and fusion using canonical correlation analysis. *IEEE Transactions on Multimedia*, 9(7):1396–1403, **2007**. 10.1109/TMM.2007.906583.
- [113] Z. Zhang, Y. Yuan, X. Shen, and Y. Li. Low resolution face recognition and reconstruction via deep canonical correlation analysis. In *2018 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pages 2951–2955. **2018**.
- [114] M. Zhang, Y. Yang, F. Shen, H. Zhang, and Y. Wang. Multi-view feature selection and classification for alzheimer’s disease diagnosis. *Multimedia Tools Appl.*, 76(8):10761–10775, **2017**. ISSN 1380-7501.

- [115] O. M. Polat and Y. Özkazanç. Image enhancement via multiple canonical correlation analysis. In *2013 21st Signal Processing and Communications Applications Conference (SIU)*, pages 1–4. **2013**.
- [116] K. G. Toker and Y. Özkazanç. Identification of linear systems via canonical correlation analysis. In *2013 21st Signal Processing and Communications Applications Conference (SIU)*, pages 1–4. **2013**.
- [117] K. G. Toker. *Kanonik Korelasyon Analizi ile Sistem Tanıma*. Master’s thesis, Hacettepe University, **2013**.
- [118] K. G. Toker and S. E. Yuksel. Deep canonical correlation analysis for hyperspectral image classification. In *Remote Sensing of the Ocean, Sea Ice, Coastal Waters, and Large Water Regions 2019*, volume 11150, pages 63 – 69. SPIE, **2019**.
- [119] M. Volpi, G. Matasci, M. F. Kanevski, and D. Tuia. Semi-supervised multiview embedding for hyperspectral data classification. *Neurocomputing*, 145:427–437, **2014**.
- [120] D. R. Hardoon, S. Szedmak, and J. Shawe-Taylor. Canonical correlation analysis: An overview with application to learning methods. *Neural Computation*, 16(12):2639–2664, **2004**.
- [121] M. Borga. *Learning Multidimensional Signal Processing*. Ph.D. thesis, Linköping University, Sweden, **1998**.
- [122] B. Ghogh, F. Karray, and M. Crowley. Eigenvalue and generalized eigenvalue problems: Tutorial. *ArXiv*, abs/1903.11240, **2019**.
- [123] V. Uurtio, J. M. Monteiro, J. Kandola, J. Shawe-Taylor, D. Fernandez-Reyes, and J. Rousu. A tutorial on canonical correlation methods. *ACM Computing Surveys*, 50(6):1–33, **2018**. ISSN 1557-7341. 10.1145/3136624.

- [124] K. G. Toker and S. E. Yuksel. Spectral-spatial nearest subspace classifier for hyperspectral image classification. *International Journal of Remote Sensing*, 43(6):2106–2133, **2022**. 10.1080/01431161.2022.2055986.
- [125] P. Ghamisi. *Spectral and spatial classification of hyperspectral data*. Ph.D. thesis, Citeseer, **2015**.
- [126] D. Stutz, A. Hermans, and B. Leibe. Superpixels: An evaluation of the state-of-the-art. *Computer Vision and Image Understanding*, 166:1–27, **2018**. ISSN 1077-3142. 10.1016/j.cviu.2017.03.007.
- [127] R. Achanta, A. Shaji, K. Smith, A. Lucchi, P. Fua, and S. Süsstrunk. SLIC superpixels compared to state-of-the-art superpixel methods. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 34(11):2274–2282, **2012**. 10.1109/TPAMI.2012.120.
- [128] R. Roscher and B. Waske. Superpixel-based classification of hyperspectral data using sparse representation and conditional random fields. In *2014 IEEE Geoscience and Remote Sensing Symposium*, pages 3674–3677. **2014**. 10.1109/IGARSS.2014.6947280.
- [129] F. Xie, Q. Gao, C. Jin, and F. Zhao. Hyperspectral image classification based on superpixel pooling convolutional neural network with transfer learning. *Remote Sensing*, 13(5):930, **2021**.
- [130] W. Huang, Y. Huang, H. Wang, Y. Liu, and H. J. Shim. Local binary patterns and superpixel-based multiple kernels for hyperspectral image classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13:4550–4563, **2020**.
- [131] J. Jiang, J. Ma, C. Chen, Z. Wang, Z. Cai, and L. Wang. Superpca: A superpixelwise pca approach for unsupervised feature extraction of hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, PP:1–13, **2018**. 10.1109/TGRS.2018.2828029.

- [132] S. Qu, X. Liu, and S. Liang. Multi-scale superpixels dimension reduction hyperspectral image classification algorithm based on low rank sparse representation joint hierarchical recursive filtering. *Sensors*, 21:3846, **2021**. 10.3390/s21113846.
- [133] C. Yang, L. Bruzzone, H. Zhao, Y. Tan, and R. Guan. Superpixel-based unsupervised band selection for classification of hyperspectral images. *IEEE Transactions on Geoscience and Remote Sensing*, 56(12):7230–7245, **2018**. 10.1109/TGRS.2018.2849443.
- [134] J. Wang, C. Tang, Z. Li, X. Liu, W. Zhang, E. Zhu, and L. Wang. Hyperspectral band selection via region-aware latent features fusion based clustering. *Information Fusion*, 79:162–173, **2022**.
- [135] A. Çalışkan, E. Batı, A. Koz, and A. A. Alatan. Superpixel based hyperspectral target detection. In *2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, pages 7010–7013. **2016**. 10.1109/IGARSS.2016.7730828.
- [136] M. Kütük. *Hiperspektral görüntüler için süperpiksel tabanlı hedef tespit yöntemleri*. Master’s thesis, Middle East Technical University, **2018**.
- [137] S. Zhang, W. Hua, G. Li, J. Liu, and Q. Wang. Superpixel and low-rank double-sparse regression hyperspectral unmixing. *Journal of Applied Remote Sensing*, 15(3):1 – 20, **2021**. 10.1117/1.JRS.15.032205.
- [138] M. Q. Alkhatib and M. Velez-Reyes. Superpixel-based hyperspectral unmixing with regional segmentation. In *IGARSS 2018 - 2018 IEEE International Geoscience and Remote Sensing Symposium*, pages 6384–6387. **2018**. 10.1109/IGARSS.2018.8518222.

- [139] H. Su, C. Jia, P. Zheng, and Q. Du. Superpixel-based weighted collaborative sparse regression and reweighted low-rank representation for hyperspectral image unmixing. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 15:393–408, **2021**.
- [140] T. Ince. Superpixel-based graph laplacian regularization for sparse hyperspectral unmixing. *IEEE Geoscience and Remote Sensing Letters*, 19:1–5, **2022**. 10.1109/LGRS.2020.3027055.
- [141] M.-Y. Liu, O. Tuzel, S. Ramalingam, and R. Chellappa. Entropy rate superpixel segmentation. In *CVPR 2011*, pages 2097–2104. **2011**. 10.1109/CVPR.2011.5995323.
- [142] O. Veksler, Y. Boykov, and P. Mehrani. Superpixels and supervoxels in an energy optimization framework. In K. Daniilidis, P. Maragos, and N. Paragios, editors, *Computer Vision – ECCV 2010*, pages 211–224. Springer Berlin Heidelberg, Berlin, Heidelberg, **2010**. ISBN 978-3-642-15555-0.
- [143] A. P. Moore, S. J. D. Prince, J. Warrell, U. Mohammed, and G. Jones. Superpixel lattices. In *2008 IEEE Conference on Computer Vision and Pattern Recognition*, pages 1–8. **2008**. 10.1109/CVPR.2008.4587471.
- [144] R. Achanta, A. Shaji, K. Smith, A. Lucchi, P. Fua, and S. Süsstrunk. SLIC superpixels. *Technical report, EPFL*, **2010**.
- [145] A. Çahşkan, A. Koz, and A. A. Alatan. Hyperspectral superpixel extraction using boundary updates based on optimal spectral similarity metric. In *2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, pages 1020–1023. **2015**. 10.1109/IGARSS.2015.7325942.
- [146] D. Comaniciu and P. Meer. Mean shift: a robust approach toward feature space analysis. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24(5):603–619, **2002**. 10.1109/34.1000236.

- [147] W. Duan, S. Li, and L. Fang. Spectral-spatial hyperspectral image classification using superpixel and extreme learning machines. In S. Li, C. Liu, and Y. Wang, editors, *Pattern Recognition*, pages 159–167. Springer Berlin Heidelberg, Berlin, Heidelberg, **2014**. ISBN 978-3-662-45646-0.
- [148] L. Fang, S. Li, X. Kang, and J. A. Benediktsson. Spectral–spatial classification of hyperspectral images with a superpixel-based discriminative sparse model. *IEEE Transactions on Geoscience and Remote Sensing*, 53(8):4186–4201, **2015**. 10.1109/TGRS.2015.2392755.
- [149] J. Li, H. Zhang, and L. Zhang. Efficient superpixel-level multitask joint sparse representation for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 53(10):5338–5351, **2015**. 10.1109/TGRS.2015.2421638.
- [150] H. Hotelling. Analysis of a complex of statistical variables into principal components. *Journal of Educational Psychology*, 24:498–520, **1933**.
- [151] B. Schölkopf, A. Smola, and K.-R. Müller. Nonlinear component analysis as a kernel eigenvalue problem. *Neural Computation*, 10(5):1299–1319, **1998**. 10.1162/089976698300017467.
- [152] F. Li, L. Xu, P. Siva, A. Wong, and D. A. Clausi. Hyperspectral image classification with limited labeled training samples using enhanced ensemble learning and conditional random fields. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8(6):2427–2438, **2015**.
- [153] Hyperspectral remote sensing scenes
. http://www.ehu.eus/ccwintco/index.php/Hyperspectral_Remote_Sensing_Scenes. [Accessed: 21-February-2018].
- [154] R. Loizzo, R. Guarini, F. Longo, T. Scopa, R. Formaro, C. Facchinetti, and G. Varacalli. Prisma: The italian hyperspectral mission. In *Int. Geosci. Remote Sens. Symp. (IGARSS)*, pages 175–178. **2018**. 10.1109/IGARSS.2018.8518512.

- [155] R. Loizzo, M. Daraio, R. Guarini, F. Longo, R. Lorusso, L. Dini, and E. Lopinto. Prisma mission status and perspective. In *Int. Geosci. Remote Sens. Symp. (IGARSS)*, pages 4503–4506. **2019**. 10.1109/IGARSS.2019.8899272.
- [156] L. Zhang, W.-D. Zhou, and B. Liu. Nonlinear nearest subspace classifier. In B.-L. Lu, L. Zhang, and J. Kwok, editors, *Neural Information Processing*, pages 638–645. Springer Berlin Heidelberg, Berlin, Heidelberg, **2011**. ISBN 978-3-642-24958-7.
- [157] Y. Zhang, Y. Ma, X. Dai, H. Li, X. Mei, and J. Ma. Locality-constrained sparse representation for hyperspectral image classification. *Information Sciences*, 546:858–870, **2021**. 10.1016/j.ins.2020.09.009.
- [158] B. Tu, X. Zhang, X. Kang, G. Zhang, J. Wang, and J. Wu. Hyperspectral image classification via fusing correlation coefficient and joint sparse representation. *IEEE Geoscience and Remote Sensing Letters*, 15(3):340–344, **2018**.
- [159] B. E. Boser, I. M. Guyon, and V. N. Vapnik. A training algorithm for optimal margin classifiers. In *Proceedings of the Fifth Annual Workshop on Computational Learning Theory, COLT '92*, pages 144–152. ACM, New York, NY, USA, **1992**. ISBN 0-89791-497-X.
- [160] B. Tu, C. Zhou, X. Liao, G. Zhang, and Y. Peng. Spectral-spatial hyperspectral classification via structural-kernel collaborative representation. *IEEE Geoscience and Remote Sensing Letters*, PP:1–5, **2020**. 10.1109/LGRS.2020.2988124.
- [161] Y. Xu, B. Du, F. Zhang, and L. Zhang. Hyperspectral image classification via a random patches network. *ISPRS Journal of Photogrammetry and Remote Sensing*, 142:344–357, **2018**. ISSN 0924-2716.
- [162] C.-C. Chang and C.-J. Lin. LIBSVM: A library for support vector machines. *ACM Transactions on Intelligent Systems and Technology*, 2:27:1–27:27,


2011. Software available at <http://www.csie.ntu.edu.tw/~cjlin/libsvm>.

- [163] R. Ge, C. Jin, S. M. Kakade, P. Netrapalli, and A. Sidford. Efficient algorithms for large-scale generalized eigenvector computation and canonical correlation analysis. In *Proceedings of the 33rd International Conference on Machine Learning, ICML 2016, New York City, NY, USA, June 19-24, 2016*, volume 48, pages 2741–2750. **2016.**



EKLER

EK 1 - Tezden Türetilmiş Yayınlar



International Journal of Remote Sensing



ISSN: (Print) (Online) Journal homepage: <https://www.tandfonline.com/loi/tres20>

Spectral-spatial nearest subspace classifier for hyperspectral image classification

Kemal Gürkan Toker & Seniha Esen Yuksel

To cite this article: Kemal Gürkan Toker & Seniha Esen Yuksel (2022) Spectral-spatial nearest subspace classifier for hyperspectral image classification, International Journal of Remote Sensing, 43:6, 2106-2133, DOI: [10.1080/01431161.2022.2055986](https://doi.org/10.1080/01431161.2022.2055986)

To link to this article: <https://doi.org/10.1080/01431161.2022.2055986>



Published online: 30 Mar 2022.



Submit your article to this journal [↗](#)



Article views: 83



View related articles [↗](#)



View Crossmark data [↗](#)

Full Terms & Conditions of access and use can be found at
<https://www.tandfonline.com/action/journalInformation?journalCode=tres20>



Spectral-spatial nearest subspace classifier for hyperspectral image classification

Kemal Gürkan Toker and Seniha Esen Yuksel 

Department of Electrical and Electronics Engineering, Hacettepe University, Ankara, Turkey

ABSTRACT

Nearest subspace classifier (NSC) is a simple classifier that works on the assumption that samples from the same class must approximately lie on the same subspace. However, NSC only considers the spectral information and neglects the spatial information. Several studies have tried to eliminate this drawback of NSC. Still, they either are not robust against outliers in the neighbourhood of the test sample or have too many parameters which need to be tuned manually. In this paper, we present a practical and straightforward method that improves the existing NSC-based approaches that utilise spatial information. In our proposed method, in addition to the assumption in NSC that samples from the same class must approximately lie on the same subspace, we assume that spatially adjacent pixels quite likely belong to the same class. By combining these two assumptions, we conclude that spatially adjacent pixels must approximately lie on the same subspace as well. Then, we propose a method that analyses the closeness between two subspaces, where one subspace is the space spanned by the neighbourhood of the test sample and the other subspace is the space spanned by the within-class training samples. The proposed method has a closed-form solution, is easy to implement, and outperforms the existing solutions when the number of labelled training samples is scarce. The source code of the paper is available at <https://github.com/kgtkoker/SSNSC-for-HSIC>.

ARTICLE HISTORY

Received 8 July 2021
Accepted 13 March 2022

1. Introduction

With the advances in hyperspectral remote sensor technology, hyperspectral images (HSI) can provide rich spectral information and can be used in a broad range of applications such as mineralogy (Acosta et al. 2019), oceanography (Devi, Ganasri and Dwarakish 2015) and military (Yuksel et al. 2013; Toksoz, Toker and Gungor 2018). However, as niche as these applications, a very high cost is associated with collecting labelled training samples. This cost might be as simple as imaging lots of data to capture the variability of the signatures or could be a more complex mapping of airborne data with the ground coordinates within an error. On the other hand, collecting lots of labelled data is sometimes impossible, such as in military scenarios. Therefore, despite the recent advances in

CONTACT Seniha Esen Yuksel,  eyuksel@ee.hacettepe.edu.tr  Department of Electrical and Electronics Engineering, Hacettepe University, Ankara, 06800, Turkey

© 2022 Informa UK Limited, trading as Taylor & Francis Group

deep learning for hyperspectral image classification (HSIC) (Audebert, Le Saux and Lefevre 2019; Paoletti et al. 2019), limited but high-dimensional training data still form a bottleneck and adversely affect most of these data-intensive algorithms' performances.

Still, some deep learning methods in the literature work well with a limited number of training samples (Jia et al. 2021). Besides limited training data and high dimensionality, researchers encounter other challenges during hyperspectral image classification (Davari et al. 2018; Koz 2019). One of these is the mixed and noisy pixels which occur due to low spatial resolution when one pixel covers several materials (Yuksel, Kucuk and Gader 2016; Irmak, Akar and Yuksel 2018). The other challenges are intra-class spectral variability and inter-class spectral similarity (Ghamisi et al. 2017; Pan, Shi and Xu 2019; Kucuk and Yuksel 2021).

To deal with these challenges, representation-based classification methods that work well even with limited training data and do not require complicated parameter tuning phases have been proposed (Li and Du 2016). Most of these representation-based methods have closed-form solutions that make them easy to implement. Further, these methods directly handle the mixed pixels problem by their nature since they assume that test samples can be represented by the combinations of training samples. Among these representation-based classification methods, sparse representation-based classification (SRC), initially developed for face recognition (Wright et al. 2009), was further studied in hyperspectral image processing (Chen, Nasrabadi and Tran 2011; Tang et al. 2014) and various machine learning applications (Guha and Ward 2012; Dong et al. 2015). Basis pursuit (BP), orthogonal matching pursuit (OMP), and their variants are used to solve the SRC problem (Chen, Nasrabadi and Tran 2011; Tropp and Gilbert 2007; Li et al. 2014a). These kinds of methods assume that the test sample can be sparsely represented by only a few training samples among the overall training samples and the class label of the test sample is determined according to the minimal class-specific reconstruction error.

A more computationally efficient alternative to SRC is the collaborative representation-based classification (CRC). In CRC, sparseness constraint is not imposed, and all the samples in the training set can contribute to the representation simultaneously; hence, the name 'collaborative'. Since it is solved as an l_2 -norm regularised least squares problem, it has a closed-form solution, resulting in a much lower computational cost than SRC with l_1 norm (Li and Du 2016; Li et al. 2019; Li and Du 2014).

As opposed to the SRC and CRC-based methods that use the whole training set to represent a test sample, the third class of classifiers, namely the nearest subspace classifier (NSC) (Zhang, Zhou and Liu 2011) and nearest-regularised-subspace (NRS), (Li et al. 2014b) focus on class-specific representation. In NSC, the idea is that the samples from the same class must lie on the same subspace (Zhang, Zhou and Liu 2011; Shu, Zhang and Tang 2019). Thus, the minimum distance between the test sample and the space spanned by the within-class training samples is computed separately. Then, the test sample is labelled as the class with the nearest subspace (minimum approximation error). In this paper, we propose a method inspired by the geometric interpretation of NSC.

Recent studies on hyperspectral image classification show that taking advantage of spatial information effectively improves classification performance (Ghamisi et al. 2018; Imani and Ghassemian 2020; Zhang et al. 2019). The use of spatial information is also widespread in representation-based methods (Li and Du 2014; Xiong et al. 2015; Chen, Nasrabadi and Tran 2011; Zhou et al. 2021; Su et al. 2020). However, NSC and NRS only

consider spectral information and neglect spatial information. In order to combine spatial information with NSC and NRS, several methods have been proposed, such as Gabor-filtering-based NRS (Gabor-NRS) (Li and Du 2014) and NRS with Markov random field (NRS-MRF) (Xiong et al. 2014), joint nearest subspace classifier (JNSC) (Bo, Lu and Wang 2016) and robust joint nearest subspace classifier (RJNSC) (Bo, Lu and Wang 2016). Naturally, extra pre-processing/post-processing steps or extra parameters are required to make such methods work. However, the parameters are hard to tune, and the additional steps are hard to design. And these complicate the implementation of such methods.

In order to overcome the shortcomings of the aforementioned methods utilising spatial information, we propose a novel representation-based approach called spectral-spatial nearest subspace classifier (SSNSC) that effectively utilises spatial and spectral information together. In addition to the assumption in NSC that samples from the same class must approximately lie on the same subspace, we assume that spatially adjacent pixels quite likely belong to the same class, as considered in other spectral-spatial methods (Li and Du 2016; Chen, Nasrabadi and Tran 2011; Bo, Lu and Wang 2016). By combining these two assumptions, we conclude that spatially adjacent pixels with similar spectral signatures must approximately lie on the same subspace. Based on these assumptions, the maximum correlation between the space spanned by the neighbourhood of the test sample, and the space spanned by the within-class training samples is computed. Then, the test sample is assigned to the class where the correlation between the space spanned by the neighbourhood of the test sample and the space spanned by the training samples is maximum. In doing so, we consider the subspace spanned by the neighbourhood of the test sample as opposed to the single test sample in NSC and find the correlation between the two subspaces as opposed to the Euclidean distance between a test sample and a subspace as in NSC. To compute the maximum correlation between two subspaces, we use canonical correlation analysis (CCA) (Hotelling 1936). Hence, we tackle NSC from a different perspective and present a novel optimisation model that jointly utilises spatial and spectral information to overcome the shortcomings of the NSC-based methods utilising spatial information. The contributions of this paper can be summarised as follows.

- We present an objective function that simply seeks the maximally correlated vector pairs located within two subspaces, where one subspace is the space spanned by the neighbourhood of the test sample and the other subspace is the space spanned by the within-class training samples. To solve the presented objective function, we utilise canonical correlation analysis. In doing so, we obtain a closed-form solution.
- To avoid the adverse effects of the noisy pixels in the neighbourhood of the test sample, adaptive weights are used for different neighbouring pixels. As mentioned earlier, these weights are determined automatically to give maximally correlated vector pairs located within two subspaces.
- There is no regularisation parameter in the presented objective function, and so no parameter tuning is necessary. The way we utilise spatial information does not require any extra pre-processing or post-processing stages in our proposed approach. Therefore, the proposed method is simple and easy to implement.

- Most importantly, by decreasing the training samples per class to 15, 10, and 5, we demonstrate that SSNSC is robust to limited training samples and is preferable when the labelled samples are scarce.

Experiments on three real hyperspectral datasets demonstrate that the proposed SSNSC method effectively utilizes spatial information and better deals with the noisy solitaire pixels (salt and pepper noise) and boundary problems. Thus, our proposed method outperforms the JNSC, RJNSC, and several other state-of-the-art classifiers when the labelled samples are scarce. In the rest of the paper, we first provide the background on representation-based classification algorithms, particularly NSC and its extensions. Then, we present our proposed approach and explain both the *geometric interpretation* and the *theory* of the proposed method. Finally, we give the experimental results on three hyperspectral datasets and summarise the observations.

2. Background

In this section, we give an overview of the NSC, the JNSC, and their extensions.

2.1. Nearest subspace classifier

Let $\mathbf{x}_{ij} \in R^d$ be the j^{th} training sample from class i , where $\mathbf{X}_i = [\mathbf{x}_{i1}, \mathbf{x}_{i2}, \dots, \mathbf{x}_{in_i}] \in R^{d \times n_i}$ is the training samples belonging to the i^{th} class, d is the number of spectral bands, and n_i is the number of training samples belonging to the i^{th} class. Let $\mathbf{X} = [\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_C] \in R^{d \times N}$ be all the training samples where $N = \sum_{i=1}^C n_i$ is the total number of training samples, and C is the number of classes.

In NSC, the term ‘subspace’ corresponds to the space spanned by $\mathbf{X}_i$, $i \in \{1, 2, \dots, C\}$, i.e. the column space of $\mathbf{X}_i$. Column space of $\mathbf{X}_i$ is the space consisting of all possible linear combinations of $\mathbf{x}_{i1}, \mathbf{x}_{i2}, \dots, \mathbf{x}_{in_i}$; and it is denoted as $\text{Col}(\mathbf{X}_i)$. Since n_i is lower than d , column spaces of $\mathbf{X}_i$'s do not span the whole d dimensional space, $\text{Col}(\mathbf{X}_i)$ is a subspace of R^d .

The idea behind the NSC is that the samples from the same class must approximately lie on the same subspace (Zhang, Zhou and Liu 2011; Shu, Zhang and Tang 2019). Assume that the label of the test sample $\mathbf{y} \in R^d$ is l , but it is not known yet. According to the idea in NSC, $\mathbf{y}$ approximately lies on subspace that is spanned by the training samples belonging to the l -th class, which is described as:

$$\begin{aligned} \mathbf{y} &\approx a_{l1}\mathbf{x}_{l1} + a_{l2}\mathbf{x}_{l2} + \dots + a_{ln_l}\mathbf{x}_{ln_l} \\ &\approx \mathbf{X}_l \mathbf{a}_l \end{aligned} \quad (1)$$

where $\mathbf{a}_l$ is the coefficient vector whose entries correspond to the weights of the training samples in $\mathbf{X}_l$. To estimate the label of $\mathbf{y}$, the minimum distance (or minimum residual $\mathbf{r}_i = \mathbf{y} - \mathbf{X}_i \mathbf{a}_i$) between the test sample $\mathbf{y}$ and the column space $\text{Col}(\mathbf{X}_i)$ is computed for each class. Then, the test sample is labelled as the class with minimum

residual, which amounts to the nearest subspace. Here, $\mathbf{X}_i \hat{\mathbf{a}}_i$ is the closest vector in $\text{Col}(\mathbf{X}_i)$ to $\mathbf{y}$, and $\hat{\mathbf{a}}_i \in \{1, 2, \dots, C\}$ is the optimal coefficient vector that gives the closest vector in $\text{Col}(\mathbf{X}_i)$ to the test sample $\mathbf{y}$, computed as:

$$\hat{\mathbf{a}}_i = \arg \min_{\mathbf{a}_i} \|\mathbf{y} - \mathbf{X}_i \mathbf{a}_i\|_2^2 \quad (2)$$

As shown in Figure 1, the nearest vector in $\text{Col}(\mathbf{X}_i)$ to the test sample is the vector where the residual is orthogonal to the subspace $\text{Col}(\mathbf{X}_i)$, given as:

$$\mathbf{X}_i^T \mathbf{r}_i = 0 \quad (3)$$

and if we expand out $\mathbf{r}_i$ with $\mathbf{y} - \mathbf{X}_i \hat{\mathbf{a}}_i$, we get

$$\begin{aligned} \mathbf{X}_i^T (\mathbf{y} - \mathbf{X}_i \hat{\mathbf{a}}_i) &= 0 \\ \mathbf{X}_i^T \mathbf{X}_i \hat{\mathbf{a}}_i &= \mathbf{X}_i^T \mathbf{y} \end{aligned} \quad (4)$$

Then, the solution is given by

$$\hat{\mathbf{a}}_i = (\mathbf{X}_i^T \mathbf{X}_i)^{-1} \mathbf{X}_i^T \mathbf{y} \quad (5)$$

This closed-form solution can also be obtained by taking gradient of $\|\mathbf{y} - \mathbf{X}_i \mathbf{a}_i\|_2^2$ w.r.t. $\mathbf{a}_i$ and then setting to zero. After computing the coefficients $\hat{\mathbf{a}}_i$ for each class, residuals for each class that give the minimum Euclidean distance between the test sample and space spanned by the within-class training samples are calculated separately via $\mathbf{r}_i = \mathbf{y} - \mathbf{X}_i \hat{\mathbf{a}}_i$; and then the label of $\mathbf{y}$ is estimated as the class with the nearest subspace, given as:

$$\text{label}(\mathbf{y}) = \arg \min_i (\|\mathbf{r}_i\|_2^2) \quad (6)$$

The steps of the NSC method are summarised in Algorithm 1.

Algorithm 1 Nearest Subspace Classifier

INPUT:

Training sets: $\mathbf{X}_i \in \mathbb{R}^{d \times n_i} \quad i \in \{1, 2, \dots, C\}$

Test sample: $\mathbf{y} \in \mathbb{R}^d$

PROCEDURE:

$$1 : \hat{\mathbf{a}}_i \leftarrow (\mathbf{X}_i^T \mathbf{X}_i)^{-1} \mathbf{X}_i^T \mathbf{y} \quad i \in \{1, 2, \dots, C\}$$

$$2 : \mathbf{r}_i \leftarrow \mathbf{y} - \mathbf{X}_i \hat{\mathbf{a}}_i \quad i \in \{1, 2, \dots, C\}$$

$$3 : \text{label}(\mathbf{y}) \leftarrow \arg \min_i (\|\mathbf{r}_i\|_2^2)$$

OUTPUT:

Residuals: $\mathbf{r}_i \quad i \in \{1, 2, \dots, C\}$

Class label estimation of $\mathbf{y}$: $\text{label}(\mathbf{y})$

2.2. NSC-based methods utilising spatial information

2.2.1. Joint nearest subspace classifier

Inspired by the joint sparsity model (Chen, Nasrabadi and Tran 2011), joint nearest subspace classifier utilises spatial information (Bo, Lu and Wang 2016) by modifying NSC. JNSC assumes that pixels in a spatial neighbourhood are highly similar or belong to the same class. Thus, the pixels in a small neighbourhood around the test pixel are simultaneously approximated by a linear combination of within-class training samples. Whereas the minimum distance between the test sample and $Col(\mathbf{X}_i)$ is sought in NSC as seen in Equation (2), in JNSC, the minimum distances between $Col(\mathbf{X}_i)$ and each pixel in the neighbourhood around the test sample are sought as given by

$$\hat{\mathbf{A}}_i = \arg \min_{\mathbf{A}_i} \|\mathbf{Y} - \mathbf{X}_i \mathbf{A}_i\|_2^2 \quad (7)$$

where $\mathbf{A}_i$ denotes the coefficient matrix and $\mathbf{Y} = [\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_m]$ represents the corresponding neighbouring pixels around the test pixel $\mathbf{y}$ within a window with size T . This window structure is constructed during the classification phase for all test samples. Here, m denotes the number of pixels that is taken into account in the window. For instance, when window size T is 3 (3×3 region is taken into account), m equals 9. When the window size is 5, m will be 25.

The optimal solution in JNSC is calculated by $\hat{\mathbf{A}}_i = (\mathbf{X}_i^T \mathbf{X}_i)^{-1} \mathbf{X}_i^T \mathbf{Y}$, similar to Equation (5). Then, the label of $\mathbf{y}$ is estimated as the class with the minimum distance.

$$label(\mathbf{y}) = \arg \min_i (\|\mathbf{Y} - \mathbf{X}_i \hat{\mathbf{A}}_i\|_2^2) \quad (8)$$

In this equation, the approximation errors for each pixel in the neighbourhood equally contribute to labelling the test pixel. This makes the JNSC method problematic, especially if the neighbourhood set $\mathbf{Y}$ includes noisy pixels or outliers. Such noisy pixels result in misclassified regions, as they are located within the spatial window of their surrounding pixels. Thus, the JNSC method is not robust against outliers in the neighbourhood set $\mathbf{Y}$.

2.2.2. Robust joint nearest subspace classifiers

The presence of inhomogeneous pixels such as noisy pixels or outliers in the neighbourhood of a test pixel negatively affects the performance of JNSC due to the equal contribution assumption. To alleviate the negative effects of outliers in the neighbourhood of a test pixel, another joint classification method called robust joint nearest subspace classifier is proposed in (Bo, Lu and Wang 2016). In RJNSC, the least soft-threshold squares method (Wang, Lu and Yang 2013) is utilised. In this method, the optimization problem is defined as follows:

$$\arg \min_{\mathbf{A}_i, \mathbf{E}} \left\{ \frac{1}{2} \|\mathbf{Y} - \mathbf{X}_i \mathbf{A}_i - \mathbf{E}\|_F^2 + \lambda \|\mathbf{E}\|_1 \right\} \quad (9)$$

where $\mathbf{A}_i$ denotes the coefficient matrix, $\mathbf{E}$ can be viewed as a Laplacian noise term, and λ is a regularisation parameter. The regularisation parameter is used to damp the effects of outliers in classification. However, the regularisation parameter has to be set manually,

and determining the value of the regularisation parameter is usually challenging. The difficulty in tuning this parameter makes this method inefficient. Also, it is not guaranteed that the effect of noisy pixels will be suppressed.

The optimal parameters $\hat{\mathbf{A}}_i$ and $\hat{\mathbf{E}}$ are obtained by implementing two basic steps iteratively. First, an outlier-free least square equation is solved by $\hat{\mathbf{A}}_i = (\mathbf{X}_i^T \mathbf{X}_i)^{-1} \mathbf{X}_i^T (\mathbf{Y} - \mathbf{E})$, then Laplacian noise term $\mathbf{E}$ is obtained by $\hat{\mathbf{E}} = S_\lambda(\mathbf{Y} - \mathbf{X}_i \hat{\mathbf{A}}_i)$, where $S_\lambda(\beta) = \max(\beta - \lambda, 0) \text{sgn}(\beta)$ is the soft-thresholding operation and $\text{sgn}(\cdot)$ is the sign function. The iterative process continues until convergence or termination. The iterative process is terminated when the stopping criterion is met (e.g. the number of iterations). Here, choosing the stopping criterion and determining the values for the stopping criterion manually are other challenging issues. After this iterative process, the label of $\mathbf{y}$ is estimated as the class with the minimum distance:

$$\text{class}(\mathbf{y}) = \arg \min_i \left\{ \|\mathbf{Y} - \mathbf{X}_i \hat{\mathbf{A}}_i - \hat{\mathbf{E}}\|_F^2 - \lambda \|\hat{\mathbf{E}}\|_1 \right\} \quad (10)$$

2.2.3. Other NSC-based methods utilising spatial information

In addition to the aforementioned spectral-spatial methods, Gabor-filtering-based NRS (Gabor-NRS) (Li and Du 2014) and NRS with Markov random field (NRS-MRF) (Xiong et al. 2014) were proposed in order to combine spatial information with the NRS classifier. Different from the aforementioned methods, these methods utilise spatial information in pre-processing or post-processing stages. In Gabor-NRS, spatial features are extracted from the HSI using Gabor filtering, and then these features are used in the NRS classifier. In NRS-MRF, first, a pixel-wise NRS classification is conducted; then, spatial information obtained by MRF is used to refine the previous pixel-wise classification results. These types of spectral-spatial classifiers are effective, but the pre-processing and post-processing stages bring extra parameters, data (features) and complexity. Since the performances of these methods are sensitive to these factors, all stages must be carefully designed.

3. Proposed method

In this study, we present a practical method with an easy-to-understand geometric interpretation to overcome the shortcomings of the NSC-based methods utilising spatial information. As stated in Section 2.2, JNSC is sensitive to noisy pixels due to the equal contribution assumption. Unlike the usage of uniform weights for different neighbouring pixels in JNSC, in our proposed method, automatically determined adaptive weights are used for different neighbouring pixels in order to avoid the adverse effects of the noisy pixels in the neighbourhood of the test sample. Moreover, the proposed objective function has no regularization parameters and thus no challenging parameter tuning is necessary, unlike as in RJNSC. Additionally, there are no extra pre-processing and post-processing stages in our proposed approach while using spatial information, unlike as in Gabor-NRS and NRS-MRF. Therefore, the proposed method is simple and easy to implement.

In our proposed method, in addition to the assumption in NSC that samples from the same class must approximately lie on the same subspace, it is assumed that spatially adjacent pixels are quite likely to belong to the same class. By combining these two assumptions, we conclude that spatially adjacent pixels must approximately lie on the




Figure 1. The geometric interpretation of (a) NSC method and (b) Proposed SSNSC method (McGarigal, Stafford and Cushman 2000).

same subspace as well. Thus, we analyse the closeness between two subspaces, where one subspace is the space spanned by the neighbourhood of the test sample and the other subspace is space spanned by the within-class training samples. There are various ways to measure the distance between two subspaces (Sharma and Rameshan 2021; Ye and Lim 2014, 2016). In this paper, we use CCA to measure the minimum distance between two subspaces and use correlation as the similarity measure.

The vector in $Col(\mathbf{X}_i)$ that has minimum distance to the test sample is sought in NSC, as shown in Figure 1. In our proposed method, we also take into account spatial information, and we seek maximally correlated vector pairs for each class, where one vector is $\mathbf{X}_i \hat{\mathbf{a}}_i$

$$\hat{a}_{i1} \mathbf{x}_{i1} + \hat{a}_{i2} \mathbf{x}_{i2} + L + \hat{a}_{in_i} \mathbf{x}_{in_i} = \mathbf{X}_i \hat{\mathbf{a}}_i$$

in $Col(\mathbf{X}_i)$ and the other one is $\mathbf{Y} \hat{\mathbf{b}}_i$

$$\hat{b}_{i1} y_1 + \hat{b}_{i2} y_2 + L + \hat{b}_{im} y_m = \mathbf{Y} \hat{\mathbf{b}}_i$$

in $Col(\mathbf{Y})$ as shown in Figure 1(b). Here $\hat{\mathbf{a}}_i$ and $\hat{\mathbf{b}}_i$ are the optimal coefficient vectors that give maximally correlated vector pairs in the subspaces $Col(\mathbf{X}_i)$ and $Col(\mathbf{Y})$, respectively.

Unlike the uniform weights for different neighbouring pixels in JNSC, the adaptive weights $\mathbf{b}_i$ are automatically obtained to find maximally correlated vector pairs located within the two aforementioned subspaces. Owing to these weights, each neighbouring pixel around the test pixel has different contributions. Since maximally correlated vector pairs in the subspaces are sought, the pixels that are uncorrelated with training samples have less contribution. Thus, the adverse effects of the noisy pixels in the neighbourhood of the test pixel can be suppressed automatically.

Based on the assumptions mentioned earlier, we expect that the test pixel belongs to the class where the correlation between the vectors in $Col(\mathbf{X}_i)$ and $Col(\mathbf{Y})$ is maximum. Thus, we first seek the maximally correlated vector pairs $\mathbf{v}_{\mathbf{x}_i} = \mathbf{X}_i \mathbf{a}_i$ and $\mathbf{v}_{\mathbf{y}_i} = \mathbf{Y} \mathbf{b}_i$ in the subspaces $Col(\mathbf{X}_i)$ and $Col(\mathbf{Y})$ respectively as follows:

$$\begin{aligned} \arg \max_{\mathbf{a}_i, \mathbf{b}_i} \rho_i &= \frac{\mathbf{v}_{\mathbf{x}_i}^T \mathbf{v}_{\mathbf{y}_i}}{\|\mathbf{v}_{\mathbf{x}_i}\| \|\mathbf{v}_{\mathbf{y}_i}\|} & i \in \{1, 2, \dots, C\} \\ &= \frac{\mathbf{a}_i^T \mathbf{X}_i^T \mathbf{Y} \mathbf{b}_i}{\|\mathbf{X}_i \mathbf{a}_i\|_2 \|\mathbf{Y} \mathbf{b}_i\|_2} \end{aligned} \quad (11)$$

This optimisation problem can be solved with the canonical correlation analysis method (Andrew et al. 2013).

3.1. Canonical correlation analysis

CCA was originally proposed to model the relationships between multiple data sets or multiple features. It has been used in many fields, such as statistics (Hair et al. 1998; Yang and Trewen 2004), system identification (Toker and Özkazanç 2013; Toker 2013), and machine learning (Zhang et al. 2018, 2017). CCA has been used in hyperspectral image classification as well (Toker and Yuksel 2019; Volpi et al. 2014), but in a completely different way than how we use it in our proposed method. In prior studies, CCA was applied before classification for feature fusion in the field of multi-view learning, in which the goal is to utilise two different kinds of features jointly to extract more expressive features. However, we use CCA to compute the maximum correlation between two subspaces, where one subspace is the space spanned by the neighbourhood of the test sample, and the other subspace is the space spanned by the within-class training samples. In other words, CCA is used to seek maximally correlated vector pairs $\mathbf{v}_{x_i} = \mathbf{X}_i \mathbf{a}_i$ and $\mathbf{v}_{y_i} = \mathbf{Y} \mathbf{b}_i$ in the subspaces $\text{Col}(\mathbf{X}_i)$ and $\text{Col}(\mathbf{Y})$, respectively, as given in Equation (11). The formulation in Equation (11) can be rewritten as

$$\arg \max_{\mathbf{a}_i, \mathbf{b}_i} \rho_i = \frac{\mathbf{a}_i^T \mathbf{C}_{\mathbf{X}_i \mathbf{Y}} \mathbf{b}_i}{\sqrt{(\mathbf{a}_i^T \mathbf{C}_{\mathbf{X}_i} \mathbf{a}_i)} \sqrt{\mathbf{b}_i^T \mathbf{C}_{\mathbf{Y}} \mathbf{b}_i}} \quad (12)$$

where $\mathbf{C}_{\mathbf{X}_i \mathbf{Y}} = \mathbf{X}_i^T \mathbf{Y}$ is the cross-covariance matrix and $\mathbf{C}_{\mathbf{X}_i}$ and $\mathbf{C}_{\mathbf{Y}}$ are the covariance matrices. Correlation is scale-invariant. Thus, there are many vector pairs in the subspaces $\text{Col}(\mathbf{X}_i)$ and $\text{Col}(\mathbf{Y})$ that have a maximum correlation with the same value. To obtain a unique solution, a constraint is added such that the vectors have unit norms. Therefore, the problem can be reformulated equivalently as a constraint optimisation problem (Hardoon, Szedmak and Shawe-Taylor 2004):

$$\begin{aligned} \arg \max_{\mathbf{a}_i, \mathbf{b}_i} \rho_i &= \mathbf{a}_i^T \mathbf{C}_{\mathbf{X}_i \mathbf{Y}} \mathbf{b}_i \\ \text{s.t.} \quad &\mathbf{a}_i^T \mathbf{C}_{\mathbf{X}_i} \mathbf{a}_i = \mathbf{b}_i^T \mathbf{C}_{\mathbf{Y}} \mathbf{b}_i = 1 \end{aligned} \quad (13)$$

The problem can be solved using the Lagrange multipliers technique as follows:

$$L = \mathbf{a}_i^T \mathbf{C}_{\mathbf{X}_i \mathbf{Y}} \mathbf{b}_i - \frac{\lambda_1}{2} (\mathbf{a}_i^T \mathbf{C}_{\mathbf{X}_i} \mathbf{a}_i - 1) - \frac{\lambda_2}{2} (\mathbf{b}_i^T \mathbf{C}_{\mathbf{Y}} \mathbf{b}_i - 1) \quad (14)$$

where λ_1 and λ_2 denote the Lagrange multipliers. Differentiating L with respect to $\mathbf{a}_i$ and $\mathbf{b}_i$ gives

$$\frac{\partial L}{\partial \mathbf{a}_i} = \mathbf{C}_{\mathbf{X}_i} \mathbf{Y} \mathbf{b}_i - \lambda_1 \mathbf{C}_{\mathbf{X}_i} \mathbf{a}_i = 0 \quad (15)$$

$$\frac{\partial L}{\partial \mathbf{b}_i} = \mathbf{C}_{\mathbf{Y} \mathbf{X}_i} \mathbf{a}_i - \lambda_2 \mathbf{C}_{\mathbf{Y}} \mathbf{b}_i = 0 \quad (16)$$

Multiplying Equations (15) and (16) from the left by $\mathbf{a}_i^T$ and $\mathbf{b}_i^T$, respectively, gives

$$\mathbf{a}_i^T \mathbf{C}_{\mathbf{X}_i} \mathbf{Y} \mathbf{b}_i - \lambda_1 (\mathbf{a}_i^T \mathbf{C}_{\mathbf{X}_i} \mathbf{a}_i) = 0 \mathbf{b}_i^T \mathbf{C}_{\mathbf{Y} \mathbf{X}_i} \mathbf{a}_i - \lambda_2 (\mathbf{b}_i^T \mathbf{C}_{\mathbf{Y}} \mathbf{b}_i) = 0 \quad (17)$$

Substituting constraints in Equation (13) into Equation (17), we get

$$\lambda_1 = \lambda_2 = \mathbf{a}_i^T \mathbf{C}_{\mathbf{X}_i} \mathbf{Y} \mathbf{b}_i = \rho_i$$

Then, Equations (15) and (16) can be rewritten as

$$\mathbf{C}_{\mathbf{X}_i} \mathbf{Y} \mathbf{b}_i = \rho_i \mathbf{C}_{\mathbf{X}_i} \mathbf{a}_i \quad (18)$$

$$\mathbf{C}_{\mathbf{Y} \mathbf{X}_i} \mathbf{a}_i = \rho_i \mathbf{C}_{\mathbf{Y}} \mathbf{b}_i \quad (19)$$

which is equivalent to the generalised eigenvalue problem of the form $\mathbf{C}_1 \mathbf{w} = \rho_i \mathbf{C}_2 \mathbf{w}$ as given by

$$\begin{bmatrix} 0 & \mathbf{C}_{\mathbf{X}_i \mathbf{Y}} \\ \mathbf{C}_{\mathbf{Y} \mathbf{X}_i} & 0 \end{bmatrix} \begin{bmatrix} \mathbf{a}_i \\ \mathbf{b}_i \end{bmatrix} = \rho_i \begin{bmatrix} \mathbf{C}_{\mathbf{X}_i} & 0 \\ 0 & \mathbf{C}_{\mathbf{Y}} \end{bmatrix} \begin{bmatrix} \mathbf{a}_i \\ \mathbf{b}_i \end{bmatrix} \quad (20)$$

The solution of the maximization problem formulated in Equation (11) is now equivalent to finding the largest eigenvalue and the corresponding eigenvectors of the given generalized eigenvalue problem. The given generalised eigenvalue problem can be solved as follows (Ghojogh, Karray and Crowley 2019; Uurtio et al. 2018):

$$\mathbf{C}_1 \mathbf{w} = \rho_i \mathbf{C}_2 \mathbf{w} \Rightarrow (\mathbf{C}_1 - \rho_i \mathbf{C}_2) \mathbf{w} = 0 \quad (21)$$

which corresponds to a linear system of equations. Linear system of equations has non-trivial solutions if and only if

$$\det(\mathbf{C}_1 - \rho_i \mathbf{C}_2) = 0 \quad (22)$$

where $\det(\cdot)$ denotes the determinant of matrix. By solving this equation, n_i different solutions (eigenvalue) can be found, where $n_i < d$. The greatest eigenvalue gives ρ_i . By putting ρ_i in Equation (21), its corresponding generalised eigenvector can be obtained. The optimal coefficients $\hat{\mathbf{a}}_i$ and $\hat{\mathbf{b}}_i$ that lead to the maximally correlated vectors $\mathbf{v}_{\mathbf{X}_i} = \mathbf{X}_i \hat{\mathbf{a}}_i$ and $\mathbf{v}_{\mathbf{Y}} = \mathbf{Y} \hat{\mathbf{b}}_i$ in the subspaces $\text{Col}(\mathbf{X}_i)$ and $\text{Col}(\mathbf{Y})$, are obtained from this generalised eigenvector (Ghojogh, Karray and Crowley 2019; Uurtio et al. 2018).

3.2. SSNSC algorithm

After computing the maximum correlations (ρ_i) between the space spanned by the neighbourhood of the test sample and space spanned by the within-class training samples $\text{Col}(\mathbf{X}_i)$ $i \in \{1, 2, \dots, C\}$ by utilizing CCA, the class label of the test sample $\mathbf{y}$ is labelled as the class which presents the maximum correlation, given as:

$$\text{label}(\mathbf{y}) = \arg \max_i (\rho_i) \quad i \in \{1, 2, \dots, C\} \quad (23)$$

The steps of the proposed SSNSC method are listed in Algorithm 2. The only parameter that must be tuned is the spatial window size. Adjusting this window size parameter is easy. Moreover, no extra pre-processing and post-processing stages are required to utilise the spatial information in our proposed approach. Therefore, the proposed method is simple and easy to implement. In addition, there is no regularisation parameter in the presented objective function, so there is also no need for challenging parameter adjustment phases in our proposed method.

Algorithm 2 Proposed SSNSC Method**INPUT:**Training sets: $\mathbf{X}_i \in \mathbb{R}^{d \times n_i}$ $i \in \{1, 2, \dots, C\}$ Spatial window size: T Neighbourhood of test sample: $\mathbf{Y} = [\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_m]$ (Note that $\mathbf{Y}$ includes the test sample $\mathbf{y}$ and $m = T^2$)**PROCEDURE:**1 : $\rho_i \leftarrow \text{CCA}(\mathbf{X}_i, \mathbf{Y})$ $i \in \{1, 2, \dots, C\}$ 2 : $\text{label}(\mathbf{y}) \leftarrow \text{argmax}(\rho_i)$ **OUTPUT:**Correlations: ρ_i $i \in \{1, 2, \dots, C\}$ Class label estimation of $\mathbf{y}$: $\text{label}(\mathbf{y})$ **4. Experimental results and analysis**

In this section, the effectiveness of the proposed SSNSC algorithm is investigated against spectral-based classification methods such as NSC (Zhang, Zhou and Liu 2011), NRS (Li et al. 2014b), structure-aware collaborative representation with Tikhonov regularization (SaCRT) (Li et al. 2019), locality-constrained sparse representation classification (LSRC) (Zhang et al. 2021). Moreover, spectral-spatial classification methods such as JNSC (Bo, Lu and Wang 2016), RJNSC (Bo, Lu and Wang 2016), correlation coefficient joint sparse representation classification (CCJSR) (Tu et al. 2018), SVM with majority voting refinement (SVM-MV), deep learning-based random patch network (RPNet) (Xu et al. 2018), and structural-kernel collaborative representation (SKCR) (Tu et al. 2020) are used to investigate the effectiveness of the proposed SSNSC algorithm.

4.1. Datasets

In order to compare the performance of the proposed classification method with other methods, we conduct experiments on three public hyperspectral datasets, namely Salinas, Indian Pines and the Botswana datasets. Table 1 summarises the details of each dataset. Salinas scene was collected with the AVIRIS sensor over Salinas Valley, California. It is a 512×217 pixels image. The spatial resolution of the image is 3.7 m. The dataset contains 16 labelled classes.

Table 1. Information of the three hyperspectral datasets.

Dataset	Sensor	Size	Spectral Range (μm)	Spatial Resolution (m)	Num. Of Bands (Reduced)	Num. Of Classes
Salinas	AVIRIS	$512 \times 217 \times 224$	0.4–2.5	3.7	204	16
Indian Pines	AVIRIS	$145 \times 145 \times 224$	0.4–2.5	20	200	16
Botswana	HYPERION	$1496 \times 256 \times 242$	0.4–2.5	30	145	14




Figure 2. Groundtruth maps of (a) Salinas (b) Indian Pines, and (c) Botswana datasets.

Indian Pines scene was collected by the AVIRIS sensor over the Indian Pines test site in north-western Indiana. It is a 145×145 pixels image with 224 spectral bands from 0.4 to $2.5 \mu\text{m}$. The dataset contains 16 labelled classes. However, some classes have too few samples, such as 20, 23, 46, etc. Most of the competing algorithms require more training data, so we randomly selected 40 samples per class for training in the experiments. Therefore, classes with few samples are removed, and only eight classes are used in the experiments. On the other hand, we will later show that our algorithm gives acceptable accuracy values as low as five training samples per class.

The Botswana dataset was captured over the Okavango Delta, Botswana, by the Hyperion sensor. The dataset consists of 14 labelled classes. It is a 1496×256 pixel image. The spatial resolution of the image is 30 m. The data have 242 spectral bands from 0.43 to $2.5 \mu\text{m}$. The motivation behind using the Botswana dataset is to investigate the performance of the methods utilising spatial information, where the spatial windows that are taken into account for test samples consist of unrelated pixels. Before conducting experiments, uncalibrated and water-corrupted bands are discarded for all datasets. Groundtruths for the aforementioned datasets are given in Figure 2. Also, ground-truth classes of each dataset and their respective sample sizes are given in Table 2.

4.2. Parameter settings

The only parameter that has to be tuned to improve the classification performance in our proposed method is the spatial window size. To evaluate the impact of the window size on classification performance, different spatial region sizes, 1×1 , 3×3 , 5×5 , 7×7 and 9×9 , are tested for all datasets. All the parameters are tested for 10 runs using different randomly selected 40 training samples per class. The overall mean classification accuracies for varying window sizes for the proposed SSNSC method are given in Table 3. On the first row, $T = 1$ indicates that pixel-wise classification is performed without taking any spatial information, and it is equivalent to the NSC method except the distance metric. In our proposed method, correlation is used as a distance metric instead of the Euclidean distance. Thus, the classification accuracies for $T = 1$ in Table 3 for different datasets are

Table 2. The ground-truth classes with number of samples for Salinas, Indian Pines and Botswana datasets, respectively!

Salinas			Indian Pines			Botswana		
Class No	Land Cover Type	# of Samples	Class No	Land Cover Type	# of Samples	Class No	Land Cover Type	# of Samples
C1	Brocoli-green-weeds-1	2009	C1	Corn-notill	1428	C1	Water	270
C2	Brocoli-green-weeds-2	3726	C2	Corn-mintill	830	C2	Hippo grass	101
C3	Fallow	1976	C3	Grass-pasture	483	C3	Floodplain grasses1	251
C4	Fallow-rough-plow	1394	C4	Hay-windrowed	478	C4	Floodplain grasses2Bricks	215
C5	Fallow-smooth	2678	C5	Soybean-notill	972	C5	Reeds1	269
C6	Stubble	3959	C6	Soybean-mintill	2455	C6	Riparian	269
C7	Celery	3579	C7	Soybean-clean	593	C7	Firescar2	259
C8	Grapes-untrained	11271	C8	Woods	1265	C8	Island interior	203
C9	Soil-vinyard-develop	6203				C9	Acacia woodlands	314
C10	Corn-senesced-green-weeds	3278				C10	Acacia shrublands	248
C11	Lettuce-romaine-4 wk	1068				C11	Acacia grasslands	305
C12	Lettuce-romaine-5 wk	1927				C12	Short mopane	181
C13	Lettuce-romaine-6 wk	916				C13	Mixed mopane	268
C14	Lettuce-romaine-7 wk	1070				C14	Exposed soils	95
C15	Vinyard-untrained	7268						
C16	Vinyard-vertical-trellis	1807						
Total		54129	Total		8504	Total		3248

Table 3. Classification accuracies of our proposed method with different spatial windows sizes for all datasets.

Window Size (T)	Salinas	Indian Pines	Botswana
1 × 1	87.33	61.55	90.83
3 × 3	92.81	80.33	98.07
5 × 5	94.32	86.22	99.02
7 × 7	94.72	87.12	98.59
9 × 9	94.44	86.00	96.38

consistent with the NSC method accuracies in Tables 4–6. Other rows show the results with varying window sizes, and the best results are highlighted in bold. Larger window sizes such as 11×11 are also tested. Since the results for larger window sizes are not satisfying, they are not mentioned in this paper.

The classification maps with different window sizes are given in Figure 3 to examine the results visually. One of the results of the aforementioned 10 runs is used for visualisation in Figure 3. That is why the overall accuracies (OA) of different window sizes in Figure 3 and Table 3 are different. It can be seen in Figure 3 that there are many misclassified solitaire pixels, also known as salt and pepper noise, in pixel-wise classification results. With increasing window size, the number of misclassified solitaire pixels diminishes. Thus, the performances for almost all the window size settings for $T \geq 1$ are

Table 4. Classification accuracies (%) of different methods for the Salinas dataset.


Class	NSC	NRS	SaCRT	LSRC	CCJSR	JNSC	RJNSC	SVM-MV	RPNet	SKCR	SSNSC
C1	99.60	99.59	99.70	99.87	100	99.56	99.55	100	98.18	100	99.95
C2	99.08	98.64	99.57	99.03	99.27	99.68	99.86	100	94.07	100	99.99
C3	98.44	99.43	97.00	97.11	99.54	99.45	99.52	99.04	99.03	100	100
C4	99.29	99.40	98.31	97.45	91.71	99.00	99.03	99.79	98.42	99.71	96.43
C5	92.28	96.16	96.64	97.24	97.19	93.00	94.92	98.70	98.67	99.02	98.75
C6	99.42	99.47	99.97	99.24	99.56	97.48	97.60	100	99.60	99.84	99.66
C7	99.45	99.40	99.74	99.23	99.61	97.06	97.11	99.97	97.08	99.90	99.93
C8	72.75	75.74	79.59	71.62	70.57	86.40	82.69	82.00	82.60	91.71	92.88
C9	96.47	98.23	99.24	98.91	99.34	96.03	96.32	99.98	99.65	99.99	99.99
C10	96.91	95.23	93.41	92.83	95.37	98.06	97.41	96.21	98.70	98.07	97.56
C11	98.40	97.13	93.55	96.68	99.69	99.05	99.19	99.95	99.26	99.96	99.63
C12	98.66	99.95	94.89	97.33	99.59	99.91	74.89	100	98.03	99.16	98.42
C13	97.30	98.02	96.73	94.94	95.66	93.71	73.71	99.24	98.89	92.57	96.67
C14	97.51	96.49	92.12	93.66	98.04	96.74	72.74	99.48	99.22	95.41	99.05
C15	60.18	66.98	63.52	68.39	75.17	63.79	75.32	80.91	88.41	94.78	75.59
C16	98.90	98.40	99.19	97.02	97.73	98.70	98.64	99.50	99.35	99.60	99.37
OA(%)	87.48	89.33	89.17	88.28	89.43	90.64	89.86	93.26	93.68	97.11	94.72
AA(%)	94.04	94.89	93.95	93.79	94.88	94.85	91.16	97.17	96.82	98.11	97.12
κ (%)	86.06	88.12	87.96	86.96	88.25	89.55	88.70	92.50	92.97	96.78	94.10

Table 5. Classification accuracies (%) of different methods for the Indian Pines dataset!


Class	NSC	NRS	SaCRT	LSRC	CCJSR	JNSC	RJNSC	SVM-MV	RPNet	SKCR	SSNSC
C1	48.21	50.10	66.17	59.37	67.50	57.48	60.45	75.28	88.26	80.62	79.18
C2	48.21	52.72	42.90	66.62	76.79	44.36	58.64	79.34	93.49	87.11	91.63
C3	83.36	87.40	85.12	90.99	92.75	79.84	89.32	94.40	96.52	94.06	91.67
C4	98.72	99.45	98.82	99.40	99.65	97.51	97.73	99.54	99.82	99.88	99.90
C5	61.96	64.35	55.99	73.37	86.59	67.17	80.47	89.90	90.88	89.59	90.28
C6	49.84	55.58	75.64	57.56	71.74	49.18	65.03	74.56	83.02	83.66	76.96
C7	49.96	55.58	45.16	66.25	75.60	50.48	70.74	93.11	96.89	92.76	97.81
C8	97.64	97.20	97.64	96.55	98.71	98.07	96.91	98.50	95.69	99.28	99.77
OA(%)	62.38	65.67	68.47	71.02	80.13	63.82	73.62	84.14	90.28	88.54	87.12
AA(%)	67.24	70.30	70.93	76.27	83.67	68.01	77.41	88.08	93.07	90.87	90.90
κ (%)	55.48	59.29	62.89	65.70	76.30	57.30	68.62	81.19	88.40	86.26	84.67

Table 6. Classification accuracies (%) of different methods for the Botswana dataset!


Class	NSC	NRS	SaCRT	LSRC	CCJSR	JNSC	RJNSC	SVM-MV	RPNet	SKCR	SSNSC
C1	99.69	100	99.78	100.00	100	99.21	99.17	100	98.74	99.52	99.26
C2	99.17	99.50	96.16	99.83	94.53	100	100	100	100	94.91	99.18
C3	96.91	98.86	99.62	99.62	99.86	99.85	99.90	100	99.19	100	99.71
C4	91.31	98.05	95.81	99.08	91.48	96.97	97.25	100	98.80	97.31	99.60
C5	85.89	88.82	90.19	85.32	86.63	97.07	96.68	83.13	95.98	93.97	97.72
C6	79.30	82.40	83.67	77.94	81.55	88.90	90.39	96.88	98.30	97.81	94.89
C7	98.99	98.49	99.76	99.04	99.95	99.81	99.81	99.88	100	99.13	100
C8	95.95	98.15	97.28	98.28	96.91	99.93	100	99.92	99.51	98.95	100
C9	83.10	90.54	94.27	91.64	89.27	95.18	95.36	97.71	99.12	99.59	98.86
C10	87.88	94.66	92.65	94.27	89.69	99.47	99.56	100	100	96.58	100
C11	94.30	93.58	95.79	96.75	98.00	99.50	99.62	96.08	98.72	95.77	99.88
C12	89.21	96.45	85.27	95.17	88.37	96.73	97.23	98.04	98.65	99.00	99.21
C13	88.94	89.78	92.60	92.36	88.56	98.99	99.07	100	98.33	95.74	99.69
C14	99.81	100	93.63	100.00	98.92	99.63	99.63	87.04	99.82	96.72	98.54
OA(%)	91.12	94.02	93.98	94.09	92.75	97.66	97.85	97.29	98.80	97.63	99.02
AA(%)	92.18	94.95	93.46	94.96	93.12	97.95	98.12	97.05	98.94	97.50	99.04
κ (%)	90.36	93.51	94.06	93.58	92.12	97.46	97.66	97.06	98.70	97.42	98.93



(a) Salinas



(b) Botswana



(c) Indian Pines

Figure 3. Illustration of the influence of spatial window size on our proposed method. Ground-truths and classification maps with different spatial windows sizes 1, 3, 5, 7, 9 for the (a) Salinas (b) Indian Pines, and (c) Botswana datasets, respectively.




Figure 4. A sample zoomed region in the Indian Pines dataset.

higher compared to the pixel-wise classification results as shown in Table 3. On the other hand, larger window sizes may cause misclassifications in the class boundaries. To better analyse the effect of the window size parameter, a sample region from the classification map of the Indian Pines dataset was selected, and the zoomed classification maps for different window sizes are given in Figure 4.

There are samples that belong to three classes in this region; Grass-pasture, Corn-min-till and Soybean-clean. With increasing window size, the spatial window around the test pixel in class boundaries is more likely to include inhomogeneous pixels such as background (unlabelled samples), noise, and pixels from other classes. Although our proposed method is robust to noise and background pixels, it can suffer from pixels belonging to other classes. Therefore, large windows result in misclassified pixels, especially in the boundaries of classes next to other class regions. In Figure 4, there are misclassified pixels on the edges of the Corn-min-till class adjacent to other classes. On the other hand, there are no misclassified pixels on the edges not surrounded by other classes for all Corn-min-till, Grass-pasture, and Soybean-clean classes. This is one of the drawbacks of our proposed method, and it can be eliminated by using superpixels (compact regions with homogenous pixels) instead of spatial windows. Due to the aforementioned reasons, large window sizes are also inappropriate. As can be seen in Table 3, the optimal window size for Indian Pines and Salinas datasets is 7, and the one for Botswana is 5. We use these settings in the experiments.

One of the advantages of our proposed method compared to others is that the only parameter that affects the quality of classification results is the spatial window size. This parameter can be easily adjusted by a prior knowledge, such as the size of the areas that are to be classified. For instance, if the area is rural such as Indian Pines and Salinas, it is expected to contain large homogeneous regions. Therefore, the optimal window size is expected to be large (e.g. 7×7). Conversely, the optimal window size must be relatively smaller (e.g. 3×3) for an urban area.

In the experiments, we ensured that all the compared methods' hyper-parameters were properly tuned. For SVM with majority voting, pixel-wise classification is performed first. The final classification result is obtained by considering the majority vote of pixels in the spatial window. We utilised grid search with five-fold cross-validation to determine the regularisation parameter C and kernel parameter γ for SVM with RBF kernel CC01a. The optimal window sizes are 11, 9 and 3 for Salinas, Indian Pines, and Botswana datasets. For NRS, a leave-one-out cross-validation strategy based on the available training samples is used for parameter tuning. For LSRC, the optimal values of the sparsity level and the number of nearest neighbour samples are

6 and 20, respectively, as given in (Zhang et al. 2021). For SaCRT, the optimal regularization parameters are $5, 1e^{-3}, 1e^{-3}$ for Indian Pine dataset, $5, 1e^{-4}, 1e^{-3}$ for Salinas dataset and $10, 1e^{-4}, 1e^{-3}$ for Botswana dataset as given in (Li et al. 2019).

For CCJSR, the optimal window size is 7 for Salinas, Indian Pines datasets and 3 for Botswana, and the optimal values of sparsity levels are 3 for Salinas and Botswana, 2 for Indian Pines. For RJNSC, the values of optimal regularisation parameter are 10^{-2} for Salinas and Botswana and 10 for Indian Pines. For JNSC and RJNSC, the optimal window sizes are 3 for all datasets. In RJNSC, the number of iterations is set to 50 for all datasets. For SKCR, the number of superpixel blocks, the nearest neighbour ratio, tradeoff parameter are set to 200, 0.5, and 0.07, respectively, as given in (Tu et al. 2020). For RPNNet parameters, the number of patches, the size of patches, the number of principal components and the network's depth are set to 20, 21, 3, and 5, respectively, as given in (Xu et al. 2018).

4.3. Results and comparison

In the experiments, we first randomly select 40 samples per class as training samples and use the remaining samples for testing. Then, in a second experiment, we lower the number of training samples progressively to 5 and show that the proposed algorithm significantly outperforms all the other algorithms on three data sets.

For each method, we perform 10 runs using different randomly selected training samples and use their means for statistics as the classification performance of any method is susceptible to the selection of training samples when the number of training samples is limited (Li et al. 2015). We remove the training samples in the test sample's spatial neighbourhood during classification while implementing the spectral-spatial methods for a fair comparison. To compare the classification performances quantitatively, mean overall accuracy (OA), mean average accuracy (AA), and mean kappa coefficient κ are used as performance measures.

4.3.1. Experiments on the Salinas dataset

The classification maps of different methods obtained with 40 training samples per class for the Salinas dataset are shown in Figure 5. As shown in Figure 5, there are many misclassified solitary pixels in classification maps illustrating the results of spectral-based methods. With the help of spatial information, spectral-spatial classification methods are effective for avoiding these solitary pixels.

Thus, the results obtained by spectral-spatial classification methods are smoother, and the performance of almost all spectral-spatial classification methods is better than the spectral-based methods. However, if the spectral-spatial classification method is not robust to noisy pixels, the noisy pixels may cause misclassified regions instead of misclassified solitary pixels. In Figure 5, these misclassified regions are seen mostly in CCJSR. On the other hand, using spatial information causes misclassifications in the class boundaries for all spectral-spatial methods, particularly for JNSC, RJNSC, and RPNNet.

The classification maps in Figure 5 show that the proposed SSNSC method effectively utilises spatial information and better deals with the problems mentioned earlier. SKCR also better deals with these kinds of problems since it uses superpixels instead of the spatial window.




Figure 5. Classification maps for the Salinas dataset obtained with different methods. 40 samples per class are used for training and the remaining samples are used for testing.

The detailed classification performances of different methods for the Salinas dataset are given in Table 4. It is noticed in Table 4 that the most challenging classes are Vinyard-untrained (C15) and Grapes-untrained (C8). Our proposed method gives the best result in classifying class C8. As stated in Section 4.2, the presence of samples belonging to other classes in the spatial window adversely affects the performance of our proposed method. That is why the performance of SSNSC is lower than SVM-MV, SKCR, and RPNNet in such classes C12, C13. On the other hand, SSNSC performs best in classes such as C9, which is isolated from other classes, because our proposed method is robust to the presence of noise and background pixels in the spatial window.

The overall accuracy of SSNSC is approximately 1.04%, 1.45%, 4%, and 4.85% higher than the RPNNet, SVM-MV, JNSC and RJNSC methods, respectively, and even higher than the others for 40 training samples. Although SKCR performs best in the overall accuracy for the Salinas dataset, the leading competitor is our proposed method.

4.3.2. Experiments on Indian Pines dataset

The detailed classification performances of different methods and their corresponding classification maps for the Indian Pines dataset using 40 training samples are shown in Table 5 and Figure 6, respectively. It can be seen that the intra-class variability, inter-class similarities, and low spatial resolution make Indian Pines a more challenging dataset compared to Salinas. Thus, the classification maps obtained by spectral-based methods seen in Figure 6 contain much more




Figure 6. Classification maps for the Indian Pines dataset obtained with alternative methods. (40 samples per class are used for training and the remaining samples are used for testing).

misclassified solitary pixels than in Figure 5. There is an overall decrease in the classification rates for all algorithms. It can be seen that the classification maps of RPNNet, SKCR, and our proposed method include smoother regions compared to other methods since they are robust to noisy pixels and inter-class similarity. Also, SSNSC performs best in classes such as Hay-windrowed (C4) and Soybean-clean (C7), and Woods (C8), which are isolated from other classes. However, almost all other class regions are very close to each other. This adversely affects our proposed method's performance and leads to misclassified pixels, especially in the boundaries of classes next to other class regions. SKCR better deals with this problem since it uses superpixels instead of the spatial window. Therefore, the performance of SSNSC is lower than SKCR and RPNNet. We will also further compare the case of fewer training samples in Section 4.3.4.

For the Indian Pines dataset, Figure 6 and Table 5 show that our proposed method has an apparent superior performance to the other methods except for the RPNNet and SKCR. The overall accuracy of SSNSC is approximately 3% and 7% higher than the SVM-MV and CCJSR methods, respectively, and even higher than the others.

4.3.3. Experiments on Botswana dataset

The detailed classification performances of different methods and their corresponding classification maps for the Botswana dataset using 40 training samples are shown in Table 6 and Figure 7 respectively. It is hard to analyse the performance of the Botswana dataset visually from Figure 7. However, when Table 6 is examined, it is noticed that the Botswana dataset is easier and the accuracies for all methods are relatively higher than the other two datasets.

Since the classes have small regions in the Botswana dataset, most test pixels are located near the borders. Thus, the spatial windows taken into account for test samples consist of incoherent, mostly unlabelled background pixels. This adversely affects the performance of some spectral-spatial methods that are not robust to such incoherent pixels in the spatial windows. Hence, spectral-based methods have higher accuracy than some of these spectral-spatial methods, such as CCJSR.




Figure 7. Classification maps for the Botswana dataset obtained with alternative methods. (40 samples per class are used for training and the remaining samples are used for testing).

As stated in [Section 4.2](#), the proposed SSNSC method is more robust to noisy and background pixels in the spatial windows around the test pixel. Thus, SSNSC performs the best in most of the classes. Also, the overall accuracy of SSNSC is approximately 0.22%, 1.17%, 1.36%, 1.39%, 1.7% higher than RpNet, RJNSC, JNSC, SKCR, SVM-MV, and about 4–5% higher than the spectral-based methods.

4.3.4. Effect of different number of training samples

In this section, the influence of small-scale training samples on the performance of methods is discussed. The performance of SSNSC is compared with 10 different methods under different numbers of training samples per class (5, 10, 15, 20, 25, 30, 35, 40) in




Figure 8. Overall classification accuracy with varying number of training samples per class for (a) Salinas, (b) Indian Pines, and (c) Botswana datasets, respectively. (The legend given in (c) is valid for all datasets).

experiments. The classification performances (OA) of the methods with different numbers of training samples per class on Salinas, Indian Pines, and Botswana datasets are shown in Figure 8.

All the methods are tested for 10 runs using different randomly selected training samples. Their means are given in the figures. Here, it can be observed that the best classification performances are achieved with the proposed SSNSC method for Botswana dataset regardless of the number of labeled training samples. When the number of training samples per class is lower than 15, the proposed algorithm significantly outperforms all the other algorithms for all three datasets. However, it is noticed that the gap between SSNSC and SKCR, RpNet shrinks with sufficient training samples, and SKCR outperforms our proposed method in a certain number of training samples for Salinas and Indian Pines datasets. Additionally, RpNet outperforms our proposed method in a certain number of training samples for Indian Pines dataset.

RpNet is inefficient when the training samples per class are lower than 10, especially for Botswana and Salinas datasets. This is expected as deep learning networks need sufficient labelled samples in the training phase to have the generalisation ability in the testing phase. On the other hand, its performance is significantly boosted by the number of training samples increase.

4.3.5. Computational complexity

The computational complexity of the methods is investigated in this section. All experiments were carried out using MATLAB on an Intel(R) Xeon(R) 3.2-GHz machine with 64 GB of RAM and 2.40 GHz. 40 training samples per class with 10 runs are used in this experiment. The training and testing samples are consistent with previous sections in Experimental Results.

The mean execution times of the methods with optimal parameters are given in Table 7 where factors such as the size of the data, the complexity of the algorithms, the window size parameter of spectral-spatial-based methods affect the results. The execution times for the Salinas dataset are generally the highest since it is the largest dataset and its optimal window size is also large. The opposite is true for the Botswana dataset.

If we focus on the execution times of the algorithms, spectral-based methods are generally faster than spectral-spatial classification methods. However, iterative optimisation steps in SaCRT and dictionary pruning steps using K-nearest neighbour in the LSRC method take time. Hence, these methods are slower than the other spectral-based methods. As mentioned earlier, the window size parameter directly affects the computational time in spectral-spatial classification methods. Among the spectral-spatial classification methods, RpNet is faster than other methods since it has a simple network architecture. SVM-MV method is also fast since it uses the LIBSVM toolbox CC01a which uses the MEX function to call the C program in MATLAB. When the JNSC and RJNSC methods are compared, it can be seen that the regularisation process in RJNSC does not significantly increase the execution time. The proposed method is the slowest one, but note that it does not have a separate training and testing stage as in the RpNet or SVM-MV. It runs around three times slower than CCJSR and LSRC, five times slower than SaCRT and more than 8–10 times slower than other spectral-spatial methods. The computational burden of the proposed method arises from (i) the complex operations (such as eigenvalue eigenvector decomposition with large matrices) in the proposed method, (ii) the use of spatial information and (iii) the use of class-specific representation.

The computational burden that arises from (i) can be overcome by using efficient algorithms for large-scale generalised eigenvector computation as in (Ge et al. 2016). To avoid the negative effect of (ii), superpixels can be used instead of the spatial window. Instead of pixel-wise classification using the spatial window, superpixels can be extracted, and then superpixelwise classification can be performed. To avoid the negative effect of (iii), the proposed method can be implemented in a distributed way by computing the correlation between two subspaces for each class simultaneously.

We also analyze the complexity of the SSNSC method with respect to the window size, training size, test size, band size and number of classes as given in Table 8. The experiments are performed on Indian Pines dataset by setting window size to 3, training size to 20, test size to 8184, band size to 200 and number of Classes to 8, and changed one at

Table 7. Execution times (in seconds) of different methods for three datasets.

Dataset	NSC	NRS	SaCRT	LSRC	CCJSR	JNSC	RJNSC	SVM-MV	RpNet	SKCR	SSNSC
Salinas	238.16	292.36	667.15	1236.92	1294.10	372.87	466.56	12.16	8.47	66.62	3941.51
Botswana	8.59	18.70	30.23	13.90	46.69	14.64	15.96	5.09	1.01	109.26	95.02
Indian Pines	17.99	29.02	29.46	105.78	100.30	27.16	29.57	2.13	1.81	16.61	249.95

Table 8. Execution times (in seconds) of the proposed SSNSC method with respect to varying window size, training size, test size, band size and number of classes.

	Window Size			Training Size			Test Size			Band Size			# of Classes		
	3 × 3	5 × 5	7 × 7	10	20	30	1000	2000	3000	50	100	150	2	4	6
Execution Time	22.93	64.27	130.75	15.75	22.93	29.67	3.72	7.47	11.37	14.01	19.38	21.11	5.86	11.09	17.18

a time with all other parameters kept constant. It can be seen that the execution time increases almost linearly with the number of pixels in the window, number of classes, test size and train size.

Although the proposed method seems slow, it does not require a separate training stage, and finding the optimal value for the window size parameter is easy by prior knowledge, as stated in Section 4.2. The process of tuning parameters in other methods is more time-consuming than our proposed method. Moreover, it is not guaranteed in other methods to find the optimal parameter by using the tuning processes such as cross-validation, especially with limited training data.

5. Conclusion

In this paper, we proposed a novel representation-based spectral-spatial classifier for HSI classification. The geometric interpretation of the proposed method is easy to understand. It simply analyses the closeness between the space spanned by the neighbourhood of the test sample and the space spanned by the within-class training samples. The way that we utilise spatial information does not require any extra pre-processing or post-processing stages. Thus, the proposed SSNSC method is easy to implement, and no parameter tuning is necessary except for the spatial window size. Experimental results demonstrate that the proposed method has much higher classification accuracies than the other spectral-spatial representation-based classifiers on three real hyperspectral datasets, especially when the number of training samples is limited. Since the proposed method effectively utilises spatial information, it is robust to salt and pepper noise and boundary problems compared to other methods.

One major limitation of the proposed method is that using the patch-wise spatial window in the proposed method causes misclassification in the boundaries, especially when the test pixel is surrounded by pixels of other classes. Second, the proposed method has a closed-form solution that is simple to implement despite being time-consuming. Addressing these problems will be the focus of our future research. Using superpixels instead of spatial windows may be a solution against these limitations at the expense of an extra stage and parameters.

Acknowledgement

The authors would like to thank ASELSAN Inc. for their support.

Disclosure statement

No potential conflict of interest was reported by the author(s).

ORCID

Seniha Esen Yuksel  <http://orcid.org/0000-0002-8868-1132>

Nomenclature

x_{ij}	j^{th} training sample from class i
$\mathbf{X}_i$	Training samples belonging to the i^{th} class
$\mathbf{y}$	Test sample
$\mathbf{Y}$	Neighbouring pixels around the test pixel $\mathbf{y}$
$\text{Col}(\mathbf{X}_i)$	Column space of $\mathbf{X}_i$
$\text{Col}(\mathbf{Y})$	Column space of $\mathbf{Y}$
r_i	Minimum Euclidean distance between the test sample and $\text{Col}(\mathbf{X}_i)$
v_{x_i}, v_{y_i}	Maximally correlated vector pairs in subspaces $\text{Col}(\mathbf{X}_i)$ and $\text{Col}(\mathbf{Y})$, respectively.
ρ_i	Maximum correlation between the maximally correlated vector pairs located within $\text{Col}(\mathbf{X}_i)$ and $\text{Col}(\mathbf{Y})$
a_i, b_i	Coefficient vectors whose entries correspond to the weights of the samples in $\mathbf{X}_i$ and $\mathbf{Y}$, respectively

References

- Acosta, I. C. C., M. Khodadadzadeh, L. Tusa, P. Ghamisi, and R. Gloaguen. 2019. "A Machine Learning Framework for Drill-Core Mineral Mapping Using Hyperspectral and High-Resolution Mineralogical Data Fusion." *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 12 (12): 4829–4842. doi:10.1109/JSTARS.2019.2924292.
- Andrew, G., R. Arora, J. Bilmes, and K. Livescu. 2013. "Deep Canonical Correlation Analysis." In Proceedings of the 30th International Conference on Machine Learning, edited by S. Dasgupta and D. McAllester, Vol. 28 of Proceedings of Machine Learning Research, 1247–1255. Atlanta, Georgia: PMLR, June 17–19.
- Audebert, N., B. Le Saux, and S. Lefevre. 2019. "Deep Learning for Classification of Hyperspectral Data: A Comparative Review." *IEEE Geoscience and Remote Sensing Magazine* 7 (2): 159–173. doi:10.1109/MGRS.2019.2912563.
- Bo, C., H. Lu, and D. Wang. 2016. "Robust Joint Nearest Subspace for Hyperspectral Image Classification." *Remote Sensing Letters* 7 (10): 915–924. doi:10.1080/2150704X.2016.1196836.
- Chang, C.-C. and C.-J. Lin. 2011. "LIBSVM: A Library for Support Vector Machines." *ACM Transactions on Intelligent Systems and Technology* 2: 27:1–27:27. Software <http://www.csie.ntu.edu.tw/~cjlin/libsvm>
- Chen, Y., N. M. Nasrabadi, and T. D. Tran. 2011. "Hyperspectral Image Classification Using Dictionary-Based Sparse Representation." *IEEE Transactions on Geoscience and Remote Sensing* 49 (10): 3973–3985. doi:10.1109/TGRS.2011.2129595.
- Davari, A., E. Aptoula, B. Yanikoglu, A. Maier, and C. Riess. 2018. "GMM-Based Synthetic Samples for Classification of Hyperspectral Images with Limited Training Data." *IEEE Geoscience and Remote Sensing Letters* 15 (6): 942–946. doi:10.1109/LGRS.2018.2817361.
- Devi, G. K., B. P. Ganasri, and G. S. Dwarakish. 2015. "Applications of Remote Sensing in Satellite Oceanography: A Review." *Aquatic Procedia* 4: 579–584. International Conference on Water Resources, Coastal and Ocean Engineering (ICWRCOE'15). doi:10.1016/j.aqpro.2015.02.075.
- Dong, G., G. Kuang, N. Wang, L. Zhao, and J. Lu. 2015. "SAR Target Recognition via Joint Sparse Representation of Monogenic Signal." *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 8 (7): 3316–3328. doi:10.1109/JSTARS.2015.2436694.
- Ge, R., C. Jin, S. M. Kakade, P. Netrapalli, and A. Sidford. 2016. "Efficient Algorithms for Large-Scale Generalized Eigenvector Computation and Canonical Correlation Analysis." Proceedings of the 33rd International Conference on Machine Learning, ICML 2016, New York City, NY, USA, June 19–24, 2016 48: 2741–2750.

- Ghamisi, P., E. Maggiori, S. Li, R. Souza, Y. Tarabla, G. Moser, A. De Giorgi, et al. 2018. "New Frontiers in Spectral-Spatial Hyperspectral Image Classification: The Latest Advances Based on Mathematical Morphology, Markov Random Fields, Segmentation, Sparse Representation, and Deep Learning." *IEEE Geoscience and Remote Sensing Magazine* 6 (3): 10–43. doi:10.1109/MGRS.2018.2854840.
- Ghamisi, P., J. Plaza, Y. Chen, J. Li, and A. J. Plaza. 2017. "Advanced Spectral Classifiers for Hyperspectral Images: A Review." *IEEE Geoscience and Remote Sensing Magazine* 5 (1): 8–32. doi:10.1109/MGRS.2016.2616418.
- Ghojogh, B., F. Karray, and M. Crowley. 2019. "Eigenvalue and Generalized Eigenvalue Problems: Tutorial." *ArXiv Abs/1903.11240*.
- Guha, T. and R. K. Ward. 2012. "Learning Sparse Representations for Human Action Recognition." *IEEE Transactions on Pattern Analysis and Machine Intelligence* 34 (8): 1576–1588. doi:10.1109/TPAMI.2011.253.
- Hair, J. F., R. L. Tatham, R. E. Anderson, and W. Black. 1998. *Multivariate Data Analysis*. 5th ed. United States: Prentice Hall.
- Hardoon, D. R., S. Szedmak, and J. Shawe-Taylor. 2004. "Canonical Correlation Analysis: An Overview with Application to Learning Methods." *Neural Computation* 16 (12): 2639–2664. doi:10.1162/0899766042321814.
- Hotelling, H. 1936. "Relations Between Two Sets of Variates." *Biometrika* 28 (3/4): 321–377. doi:10.1093/biomet/28.3-4.321.
- Imani, M. and H. Ghassemian. 2020. "An Overview on Spectral and Spatial Information Fusion for Hyperspectral Image Classification: Current Trends and Challenges." *Information Fusion* 59: 59–83. doi:10.1016/j.inffus.2020.01.007.
- Irmak, H., G. B. Akar, and S. E. Yuksel. 2018. "A MAP-Based Approach for Hyperspectral Imagery Super-Resolution." *IEEE Transactions on Image Processing* 27 (6): 2942–2951. doi:10.1109/TIP.2018.2814210.
- Jia, S., S. Jiang, Z. Lin, N. Li, M. Xu, and S. Yu. 2021. "A Survey: Deep Learning for Hyperspectral Image Classification with Few Labeled Samples." *Neurocomputing* 448: 179–204. doi:10.1016/j.neucom.2021.03.035.
- Koz, A. 2019. "Ground-Based Hyperspectral Image Surveillance Systems for Explosive Detection: Part I—state of the Art and Challenges." *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 12 (12): 4746–4753. doi:10.1109/JSTARS.2019.2957484.
- Kucuk, S. and S. Yuksel. 2021. "Total Utility Metric Based Dictionary Pruning for Sparse Hyperspectral Unmixing." *IEEE Transactions on Computational Imaging* 1–1.
- Li, W. and Q. Du. 2014. "Gabor-Filtering-Based Nearest Regularized Subspace for Hyperspectral Image Classification." *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 7 (4): 1012–1022. doi:10.1109/JSTARS.2013.2295313.
- Li, W. and Q. Du. 2014. "Joint Within-Class Collaborative Representation for Hyperspectral Image Classification." *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 7: 2200–2208. doi:10.1109/JSTARS.2014.2306956.
- Li, W. and Q. Du. 2016. "A Survey on Representation-Based Classification and Detection in Hyperspectral Remote Sensing Imagery." *Pattern Recognition Letters* 83: 115–123. Advances in Pattern Recognition in Remote Sensing. doi:10.1016/j.patcog.2015.08.004.
- Li, W., E. W. Tramel, S. Prasad, and J. E. Fowler. 2014b. "Nearest Regularized Subspace for Hyperspectral Classification." *IEEE Transactions on Geoscience and Remote Sensing* 52 (1): 477–489. doi:10.1109/TGRS.2013.2241773.
- Li, F., L. Xu, P. Siva, A. Wong, and D. A. Clausi. 2015. "Hyperspectral Image Classification with Limited Labeled Training Samples Using Enhanced Ensemble Learning and Conditional Random Fields." *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 8 (6): 2427–2438. doi:10.1109/JSTARS.2015.2414816.

- Li, J., H. Zhang, Y. Huang, and L. Zhang. 2014a. "Hyperspectral Image Classification by Nonlocal Joint Collaborative Representation with a Locally Adaptive Dictionary." *IEEE Transactions on Geoscience and Remote Sensing* 52 (6): 3707–3719. doi:[10.1109/TGRS.2013.2274875](https://doi.org/10.1109/TGRS.2013.2274875).
- Li, W., Y. Zhang, N. Liu, Q. Du, and R. Tao. 2019. "Structure-Aware Collaborative Representation for Hyperspectral Image Classification." *IEEE Transactions on Geoscience and Remote Sensing* 1–16.
- McGarigal, K., S. G. Stafford, and S. A. Cushman. 2000. *Multivariate Statistics for Wildlife and Ecology Research*. New York: Springer.
- Pan, B., Z. Shi, and X. Xu. 2019. "Multiobjective-Based Sparse Representation Classifier for Hyperspectral Imagery Using Limited Samples." *IEEE Transactions on Geoscience and Remote Sensing* 57 (1): 239–249. doi:[10.1109/TGRS.2018.2853268](https://doi.org/10.1109/TGRS.2018.2853268).
- Paoletti, M. E., J. M. Haut, J. Plaza, and A. Plaza. 2019. "Deep Learning Classifiers for Hyperspectral Imaging: A Review." *ISPRS Journal of Photogrammetry and Remote Sensing* 158: 279–317. doi:[10.1016/j.isprsjprs.2019.09.006](https://doi.org/10.1016/j.isprsjprs.2019.09.006).
- Sharma, K. and R. Rameshan. 2021. "Image Set Classification Using a Distance-Based Kernel Over Affine Grassmann Manifold." *IEEE Transactions on Neural Networks and Learning Systems* 32 (3): 1082–1095. doi:[10.1109/TNNLS.2020.2980059](https://doi.org/10.1109/TNNLS.2020.2980059).
- Shu, T., B. Zhang, and Y. Y. Tang. 2019. "Multi-View Classification via a Fast and Effective Multi-View Nearest-Subspace Classifier." *IEEE Access* 7: 49669–49679. doi:[10.1109/ACCESS.2019.2910322](https://doi.org/10.1109/ACCESS.2019.2910322).
- Su, H., Y. Yu, Z. Wu, and Q. Du. 2020. "Random Subspace-Based K-Nearest Class Collaborative Representation for Hyperspectral Image Classification." *IEEE Transactions on Geoscience and Remote Sensing* 1–14.
- Tang, Y., X. Li, Y. Xu, Y. Liu, J. Wang, C. Liu, and S. Liu. 2014. "Hyperspectral Image Classification Using Sparse Representation-Based Classifier." In 2014 IEEE Geoscience and Remote Sensing Symposium, Quebec City, QC, Canada, 3450–3453.
- Toker, K. G. 2013. "Kanonik Korelasyon Analizi lie Sistem Tanma."
- Toker, K. G. and Y. Özkazanç. 2013. "Identification of Linear Systems via Canonical Correlation Analysis." In 2013 21st Signal Processing and Communications Applications Conference (SIU), Haspolat, Turkey, April 1–4.
- Toker, K. G. and S. E. Yuksel. 2019. "Deep Canonical Correlation Analysis for Hyperspectral Image Classification." *Remote Sensing of the Ocean, Sea Ice, Coastal Waters, and Large Water Regions 2019* 11150: 63–69. SPIE.
- Toksoz, M. A., K. G. Toker, and G. G. Gungor. 2018. "An Automatic Dictionary Construction Framework for Sparsity-Based Hyperspectral Target Detectors." *IEEE Geoscience and Remote Sensing Letters* 15 (8): 1264–1268. doi:[10.1109/LGRS.2018.2835759](https://doi.org/10.1109/LGRS.2018.2835759).
- Tropp, J. A. and A. C. Gilbert. 2007. "Signal Recovery from Random Measurements via Orthogonal Matching Pursuit." *IEEE Transactions on Information Theory* 53 (12): 4655–4666. doi:[10.1109/TIT.2007.909108](https://doi.org/10.1109/TIT.2007.909108).
- Tu, B., X. Zhang, X. Kang, G. Zhang, J. Wang, and J. Wu. 2018. "Hyperspectral Image Classification via Fusing Correlation Coefficient and Joint Sparse Representation." *IEEE Geoscience and Remote Sensing Letters* 15 (3): 340–344. doi:[10.1109/LGRS.2017.2787338](https://doi.org/10.1109/LGRS.2017.2787338).
- Tu, B., C. Zhou, X. Liao, G. Zhang, and Y. Peng. 2020. "Spectral-Spatial Hyperspectral Classification via Structural-Kernel Collaborative Representation." *IEEE Geoscience and Remote Sensing Letters* 1–5.
- Uurtio, V., J. M. Monteiro, J. Kandola, J. Shawe-Taylor, D. Fernandez-Reyes, and J. Rousu. 2018. "A Tutorial on Canonical Correlation Methods." *ACM Computing Surveys* 50 (6): 1–33. doi:[http://dx.doi.org/10.1145/3136624](https://doi.org/http://dx.doi.org/10.1145/3136624).
- Volpi, M., G. Matasci, M. F. Kanevski, and D. Tuia. 2014. "Semi-Supervised Multiview Embedding for Hyperspectral Data Classification." *Neurocomputing* 145: 427–437. doi:[10.1016/j.neucom.2014.05.010](https://doi.org/10.1016/j.neucom.2014.05.010).
- Wang, D., H. Lu, and M. Yang. 2013. "Least Soft-Threshold Squares Tracking." In 2013 IEEE Conference on Computer Vision and Pattern Recognition, Portland, OR, USA, 2371–2378.

- Wright, J., A. Y. Yang, A. Ganesh, S. S. Sastry, and Y. Ma. 2009. "Robust Face Recognition via Sparse Representation." *IEEE Transactions on Pattern Analysis and Machine Intelligence* 31 (2): 210–227. doi:10.1109/TPAMI.2008.79.
- Xiong, M., Q. Ran, W. Li, J. Zou, and Q. Du. 2015. "Hyperspectral Image Classification Using Weighted Joint Collaborative Representation." *IEEE Geoscience and Remote Sensing Letters* 12: 1–5.
- Xiong, M., F. Zhang, Q. Ran, W. Hu, and W. Li. 2014. "Representation-Based Classifications with Markov Random Field Model for Hyperspectral Urban Data." *Journal of Applied Remote Sensing* 8 (1): 1–12. doi:10.1117/1.JRS.8.085097.
- Xu, Y., B. Du, F. Zhang, and L. Zhang. 2018. "Hyperspectral Image Classification via a Random Patches Network." *ISPRS Journal of Photogrammetry and Remote Sensing* 142: 344–357. doi:10.1016/j.isprsjprs.2018.05.014.
- Yang, K. and J. Trewin. 2004. *Multivariate Statistical Methods in Quality Management*. McGraw-Hill Engineering Reference. United States: McGraw-Hill Education.
- Ye, K. and L.-H. Lim. 2014. "Distance Between Subspaces of Different Dimensions."
- Ye, K. and L.-H. Lim. 2016. "Schubert Varieties and Distances Between Subspaces of Different Dimensions." *SIAM Journal on Matrix Analysis and Applications* 37 (3): 1176–1197. doi:10.1137/15M1054201.
- Yuksel, S. E., T. Dubroca, R. E. Hummel, and P. D. Gader. 2013. "Differential Reflection Spectroscopy: A Novel Method for Explosive Detection." *Acta Physica Polonica A* 123 (2): 263–264. doi:10.12693/APhysPolA.123.263.
- Yuksel, S. E., S. Kucuk, and P. D. Gader. 2016. "SPICEE: An Extension of SPICE for Sparse Endmember Estimation in Hyperspectral Imagery." *IEEE Geoscience and Remote Sensing Letters* 13 (12): 1910–1914. doi:10.1109/LGRS.2016.2617316.
- Zhang, Y., Y. Ma, X. Dai, H. Li, X. Mei, and J. Ma. 2021. "Locality-Constrained Sparse Representation for Hyperspectral Image Classification." *Information Sciences* 546: 858–870. doi:10.1016/j.ins.2020.09.009.
- Zhang, M., Y. Yang, F. Shen, H. Zhang, and Y. Wang. 2017. "Multi-View Feature Selection and Classification for Alzheimer's Disease Diagnosis." *Multimedia Tools and Applications* 76 (8): 10761–10775. doi:10.1007/s11042-015-3173-5.
- Zhang, Z., Y. Yuan, X. Shen, and Y. Li. 2018. "Low Resolution Face Recognition and Reconstruction via Deep Canonical Correlation Analysis." In 2018 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), Calgary, AB, Canada, 2951–2955.
- Zhang, L., Q. Zhang, B. Du, X. Huang, Y. Tang, and D. Tao. 2019. "Simultaneous Spectral-Spatial Feature Selection and Extraction for Hyperspectral Images." 4.
- Zhang, L., W.-D. Zhou, and B. Liu. 2011. "Nonlinear Nearest Subspace Classifier." In *Neural Information Processing*, edited by B.-L. Lu; L. Zhang; J. Kwok; B.-L. Lu; L. Zhang, and J. Kwok 638–645. Berlin, Heidelberg: Springer Berlin Heidelberg.
- Zhou, C., B. Tu, Q. Ren, and S. Chen. 2021. "Spatial Peak-Aware Collaborative Representation for Hyperspectral Imagery Classification." *IEEE Geoscience and Remote Sensing* 1–5.