

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

HARİTA MÜHENDİSLİĞİ ANABİLİM DALI

GÖRÜNTÜ KAYNAŞTIRMA YÖNTEMLERİNDE PERFORMANS ANALİZİ

YÜKSEK LİSANS TEZİ

Harita Müh. Volkan YILMAZ

**ARALIK 2012
TRABZON**

KARADENİZ TEKNİK ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

HARİTA MÜHENDİSLİĞİ ANABİLİM DALI

GÖRÜNTÜ KAYNAŞTIRMA YÖNTEMLERİNDE PERFORMANS ANALİZİ

Harita Müh. Volkan YILMAZ

**Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde
“HARİTA YÜKSEK MÜHENDİSİ”
Unvanı Verilmesi İçin Kabul Edilen Tezdir.**

**Tezin Enstitüye Verildiği Tarih : 10.12.2012
Tezin Savunma Tarihi : 27.12.2012**

Tez Danışmanı : Doç. Dr. Oğuz GÜNGÖR

Trabzon 2012

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü
Harita Mühendisliği Anabilim Dalında
Volkan YILMAZ tarafından hazırlanan

GÖRÜNTÜ KAYNAŞTIRMA YÖNTEMLERİNDE PERFORMANS ANALİZİ

**başlıklı bu çalışma, Enstitü Yönetim Kurulunun 11 / 12 / 2012 gün ve 1485 sayılı
kararıyla oluşturulan jüri tarafından yapılan sınavda**

YÜKSEK LİSANS TEZİ
olarak kabul edilmiştir.

Jüri Üyeleri

Başkan : Doç. Dr. Oğuz GÜNGÖR

Üye : Doç. Dr. Fevzi KARSLI

Üye : Doç. Dr. Abdulaziz GÜNEROĞLU

Prof. Dr. Sadettin KORKMAZ
Enstitü Müdürü

ÖNSÖZ

“Görüntü Kaynaştırma Yöntemlerinde Performans Analizi” başlıklı çalışma Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Harita Mühendisliği Anabilim Dalında yüksek lisans tezi olarak hazırlanmıştır.

Tez süreci boyunca bilgi birikimini, tecrübesini ve sabrını benden esirgemeyen, fikirleri ile vizyonumu her geçen gün geliştirmeyi hedefleyen çok değerli tez danışmanım Doç. Dr. Oğuz GÜNGÖR’ e en içten teşekkürlerimi sunarım.

Tez döneminde zaman zaman desteklerini gördüğüm mesai arkadaşlarım Arş. Gör. Özlem AKAR ve Arş. Gör. Deniz YILDIRIM’ a teşekkürlerimi sunarım.

Tez dönemi boyunca manevi destekleriyle her zaman yanımda olan sevgili arkadaşım Çiğdem ŞERİFOĞLU, mesai arkadaşlarım Arş. Gör. Mustafa ULUKAVAK ve Arş. Gör. Ziya USTA ve değerli ağabeyim Sadık KARAKOÇ’ a teşekkürü borç bilirim.

Son olarak bugünlere gelmemde büyük pay sahibi olan ve manevi desteklerini her zaman hissettiğim aileme sonsuz teşekkürlerimi sunarım.

Volkan YILMAZ

Trabzon 2012

TEZ BEYANNAMESİ

Yüksek Lisans Tezi olarak sunduğum “GÖRÜNTÜ KAYNAŞTIRMA YÖNTEMLERİNDE PERFORMANS ANALİZİ” başlıklı bu çalışmayı baştan sona kadar danışmanım Doç. Dr. Oğuz GÜNGÖR’ ün sorumluluğunda tamamladığımı, verileri/örnekleri kendim topladığımı, deneyleri/analizleri ilgili laboratuvarında yaptığımı/yaptırdığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 10.12.2012

Volkan YILMAZ

İÇİNDEKİLER

	<u>Sayfa No.</u>
ÖNSÖZ.....	III
TEZ BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET	VIII
SUMMARY	IX
ŞEKİLLER DİZİNİ	X
TABLolar DİZİNİ.....	XVII
SEMBOLLER DİZİNİ	XX
1. GENEL BİLGİLER.....	1
1.1. Giriş.....	1
1.2. Problemin Tanımı	4
1.3. Çalışmanın Amacı.....	4
1.4. Metodoloji.....	5
1.5. Görüntü Kaynaştırma.....	5
1.5.1. Görüntü Kaynaştırmada Dikkat Edilmesi Gereken Hususlar	7
1.5.2. Ön İşleme (Preprocessing).....	9
1.5.2.1. Geometrik Düzeltme	9
1.5.2.2. Radyometrik Düzeltme	12
1.5.2.3. Histogram Eşleme (Histogram Matching).....	13
1.5.3. Görüntü Kaynaştırma Yöntemleri.....	15
1.5.3.1. IHS (Intensity - Hue – Saturation) Dönüşümü ile Görüntü Kaynaştırma..	15
1.5.3.2. Temel Bileşenler Analizi (PCA) Dönüşümü ile Görüntü Kaynaştırma	18
1.5.3.3. Brovey, SVR ve CN Yöntemleri ile Görüntü Kaynaştırma	20
1.5.3.4. Ehlers Görüntü Kaynaştırma Yöntemi.....	21
1.5.3.5. Multiplicative Görüntü Kaynaştırma Yöntemi	22
1.5.3.6. HPF (High-Pass Filter) Görüntü Kaynaştırma Yöntemi.....	22
1.5.3.7. Gram-Schmidt Dönüşümü ile Görüntü Kaynaştırma	22
1.5.3.8. Kriter Tabanlı Görüntü Kaynaştırma Yöntemi	25
1.5.3.9. Dalgacık Dönüşümü ile Görüntü Kaynaştırma.....	27

1.5.3.9.1.	2 Boyutlu Dalgacık Dönüşümü.....	27
1.5.3.10	Yeni Bir Yöntem	29
1.5.4.	Kaynaştırılmış Görüntülerin Kalitelerinin Değerlendirilmesi	30
1.5.4.1.	RMSE.....	30
1.5.4.2.	RASE	31
1.5.4.3.	ERGAS	32
1.5.4.4.	SAM.....	33
1.5.4.5.	SID	34
1.6.	Görüntü Sınıflandırma	35
1.6.1.	Kontrollü Sınıflandırma (Supervised Classification).....	36
1.6.1.1.	Parametrik Olmayan Karar Kuralları.....	37
1.6.1.1.1.	Öznitelik Uzayı (Feature Space) Karar Kuralı.....	37
1.6.1.2.	Parametrik Karar Kuralları	38
1.6.1.2.1.	En Yakın Mesafe (Minimum Distance) Karar Kuralı	38
1.6.1.2.2.	Maksimum Benzerlik (Maximum Likelihood) Karar Kuralı.....	39
1.6.1.3.	Destek Vektör Makineleri (Support Vector Machines) ile Sınıflandırma	40
1.6.1.3.1.	Doğrusal Destek Vektör Makineleri.....	41
1.6.1.3.2.	Doğrusal Olmayan Destek Vektör Makineleri	44
1.6.1.3.3.	Çok Sınıflı Destek Vektör Makineleri.....	45
1.6.1.4.	Yapay Sinir Ağları (Artificial Neural Network) ile Sınıflandırma.....	47
1.6.1.4.1.	Geri Yayılım (Back Propagation).....	49
1.6.1.5.	İkili Kodlama (Binary Encoding) Sınıflandırma Yöntemi	50
1.6.1.6.	Rastgele Orman (Random Forest) Sınıflandırma Yöntemi.....	51
1.6.2.	Kontrolsüz Sınıflandırma (Unsupervised Classification)	52
2.	YAPILAN ÇALIŞMALAR	54
2.1.	Çalışma Bölgeleri, Kullanılan Uydu Görüntüleri ve Yazılımlar	54
2.2.	Gerçekleştirilen İşlemler	56
3.	BULGULAR VE İRDELEMELER.....	59
3.1.	Nicel Değerlendirme	59
3.1.1.	Genel Değerlendirme	69
3.2.	Görsel Değerlendirme	70
3.2.1.	IHS Kaynaştırması	75
3.2.2.	Brovvey Kaynaştırması.....	80

3.2.3.	Ehlers Kaynařtırması	85
3.2.4.	HPF Kaynařtırması	90
3.2.5.	Multiplicative Kaynařtırması.....	96
3.2.6.	PCA Kaynařtırması	101
3.2.7.	Dalgacık Dönüřümü Kaynařtırması	106
3.2.8.	CN Kaynařtırması	112
3.2.9.	Gram-Schmidt Kaynařtırması.....	117
3.2.10.	Kriter Tabanlı Görüntü Kaynařtırması.....	122
3.2.11.	Yeni Yöntem ile Kaynařtırma	128
3.3.	Genel Deęerlendirme	134
4.	SONUÇLAR VE ÖNERİLER.....	135
5.	KAYNAKLAR	139
6.	EKLER.....	144
ÖZGEÇMİŐ		

Yüksek Lisans Tezi

ÖZET

GÖRÜNTÜ KAYNAŞTIRMA YÖNTEMLERİNDE PERFORMANS ANALİZİ

Volkan YILMAZ

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Harita Mühendisliği Anabilim Dalı
Danışman: Doç. Dr. Oğuz GÜNGÖR
2012, 143 Sayfa, 53 Ek Sayfa

Görüntü kaynaştırma konumsal çözünürlüğü yüksek olan bir görüntüdeki konumsal detayların konumsal çözünürlüğü düşük olan görüntülere transfer edilmesidir. Farklı görüntü kaynaştırma yöntemleri farklı kalitede kaynaşmış görüntüler sunmaktadır. Bu yöntemlerden bazıları düşük konumsal çözünürlüklü görüntünün spektral yapısını bozabilmektedir. Literatürde kaynaştırılmış görüntülerin konumsal ve spektral kalitelerinin belirlenmesinde kullanılan bazı metrikler bulunmaktadır. Bu metrikler bazı dezavantajlarından dolayı özellikle kaynaştırılmış görüntünün spektral kalitesini gerektiği şekilde ölçemeyebilmektedirler. Bu çalışmadaki amaç kaynaştırılmış görüntülerin spektral kalitelerinin sınıflandırma sonrası doğruluk analizleriyle ortaya koyulmasıdır. Bu amaçla pilot bölgelere ait Worldview-2, Landsat ETM+ ve Ikonos çok bantlı görüntüleri kendi pankromatik bantlarıyla, bir başka Ikonos görüntüsü ise Quickbird pan-sharpened görüntüsüyle 11 kaynaştırma yöntemi kullanılarak kaynaştırılmıştır. Bu yöntemler IHS, CN, HPF, PCA, Multiplicative, Ehlers, Brovey, Dalgacık Dönüşümü, Gram-Schmidt, Kriter Tabanlı Kaynaştırma yöntemi ve literatüre yeni katılan bir yöntemdir. Kaynaştırılan görüntüler aynı imzalar kullanılarak 6 sınıflandırma yöntemiyle sınıflandırılmıştır. Bu yöntemler En Yakın Mesafe, İkili Kodlama, Destek Vektör Makineleri, Rastgele Orman, Maksimum Benzerlik ve Yapay Sinir Ağları yöntemleridir. Kaynaştırılmış görüntüler için bazı metrikler uygulanmıştır. Sınıflandırma sonuçları ve metrikler birlikte değerlendirildiğinde HPF yönteminin konumsal detayı artırırken bu çalışma kapsamındaki görüntülerin spektral yapısına minimum zarar veren yöntem olduğu belirlenmiştir.

Anahtar Kelimeler: Uzaktan Algılama, Görüntü Kaynaştırma, Görüntü Sınıflandırma, Doğruluk Analizi, Metrikler

Master Thesis

SUMMARY

PERFORMANCE ANALYSIS ON IMAGE FUSION METHODS

Volkan YILMAZ

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Geomatics Engineering Graduate Programme
Supervisor: Assoc. Prof. Oğuz GÜNGÖR
2012, 143 Pages, 53 Appendix Pages

Transferring spatial details of a high-resolution image into a low-resolution multispectral image is called image fusion. Different fusion methods produce different quality fused images. Some of these methods may damage to the spectral quality of low-resolution multispectral image while transferring spatial details into it. In literature, there are some metrics that are used to evaluate the spectral and spatial quality of fused images. These metrics have some disadvantages so they may not be successful to examine the spectral quality of fused images. The main goal of this study is to present the spectral qualities of fused images using post-classification accuracy analysis. In order to do this, Worldview-2, Landsat ETM+ and Ikonos multispectral images are fused with their own panchromatic bands and another Ikonos image is fused with Quickbird pan-sharpened image by using 11 different fusion methods. These methods are IHS, CN, HPF, PCA, Multiplicative, Ehlers, Brovey, Wavelet, Gram-Schmidt, Criteria Based Fusion Method and a novel method in literature. Some metrics that are used to evaluate the quality of fused images are performed. Fused images are then classified with 6 different classification methods by using exactly the same signatures. Minimum Distance, Binary Encoding, Support Vector Machines, Random Forest, Maximum Likelihood and Artificial Neural Network classification methods are used. Examining the classification results and metrics together, HPF image fusion method is found out to be the most successful one in preserving the spectral quality of the data sets used while increasing the spatial resolution.

Key Words: Remote Sensing, Image Fusion, Image Classification, Accuracy Assessment, Quality Metrics

ŞEKİLLER DİZİNİ

	<u>Sayfa No.</u>
Şekil 1.	Görüntü Kaynaştırma..... 6
Şekil 2.	Aynı bölgeye ait ALI (solda) ve Ikonos (sağda) pankromatik görüntüleri.... 7
Şekil 3.	Geometrik düzeltme..... 10
Şekil 4.	De-striping hatası 13
Şekil 5.	Histogram eşleme..... 14
Şekil 6.	3 seviye için WD görüntü piramidi 28
Şekil 7.	2 Boyutlu ayrık dalgacık dönüşümü akışı 28
Şekil 8.	Orijinal görüntü (solda) ve orijinal görüntüye ait 2 seviyeli AA, YA, AY ve YÜY alt görüntüleri 29
Şekil 9.	Sınıflandırma işleminin şematik gösterimi Görüntü Kaynaştırma 35
Şekil 10.	İki sınıf için optimum hiper düzlem 42
Şekil 11.	Doğrusal olmayan verilerin yüksek boyutlu başka uzaya dönüşümü 45
Şekil 12.	Basit bir yapay sinir ağı (üstte) ve bu ağa ait örnek bir düğüm (altta)..... 48
Şekil 13.	Çalışma bölgeleri 54
Şekil 14.	Orijinal Worldview-2 (WV2) çok bantlı görüntüsü (üstte) ve aynı uyduya ait pankromatik bant (altta) 57
Şekil 15.	Orijinal Landsat ETM+ çok bantlı görüntüsü (üstte) ve aynı uyduya ait pankromatik bant (altta)..... 57
Şekil 16.	Orijinal Ikonos çok bantlı görüntüsü (solda) ve aynı uyduya ait pankromatik bant (sağda)..... 58
Şekil 17.	Orijinal Ikonos çok bantlı görüntüsü (solda) ve Quickbird pan-sharpened görüntüsünden elde edilen pankromatik bant (QBPan) (sağda)..... 58
Şekil 18.	Orijinal Worldview-2 görüntüsünün pankromatik bandıyla kaynaştırılmasıyla üretilen kaynaştırılmış görüntülerin sınıflandırma doğrulukları 71
Şekil 19.	Orijinal Landsat ETM+ görüntüsünün pankromatik bandıyla kaynaştırılmasıyla üretilen kaynaştırılmış görüntülerin sınıflandırma doğrulukları 73
Şekil 20.	Orijinal Ikonos görüntüsünün pankromatik bandıyla kaynaştırılmasıyla üretilen kaynaştırılmış görüntülerin sınıflandırma doğrulukları 73
Şekil 21.	Orijinal Ikonos ve QBPan görüntülerinin kaynaştırılmasıyla üretilen kaynaştırılmış görüntülerin sınıflandırma doğrulukları 74

Şekil 22.	Orjinal görüntü ve IHS kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Worldview-2 MS – Worldview-2 Pan).....	75
Şekil 23.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), IHS kaynaştırılmış görüntüsü (c), IHS kaynaştırılmış görüntüsünün sınıflandırılması (d) (Worldview-2 MS – Worldview-2 Pan).....	76
Şekil 24.	Orjinal görüntü ve IHS kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Landsat ETM+ MS – Landsat ETM+ Pan).....	76
Şekil 25.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), IHS kaynaştırılmış görüntüsü (c), IHS kaynaştırılmış görüntüsünün sınıflandırılması (d) (Landsat ETM+ MS – Landsat ETM+ Pan)	77
Şekil 26.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), IHS kaynaştırılmış görüntüsü (c), IHS kaynaştırılmış görüntüsünün sınıflandırılması (d) (Ikonos MS – Ikonos Pan)	78
Şekil 27.	Orjinal görüntü ve IHS kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Ikonos MS – Ikonos Pan).....	79
Şekil 28.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), IHS kaynaştırılmış görüntüsü (c), IHS kaynaştırılmış görüntüsünün sınıflandırılması (d) (Ikonos MS – QBPan).....	79
Şekil 29.	Orjinal görüntü ve IHS kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Ikonos MS – QBPan).....	80
Şekil 30.	Orjinal görüntü ve IHS kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Worldview-2 MS – Worldview-2 Pan).....	81
Şekil 31.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Brovey kaynaştırılmış görüntüsü (c), Brovey kaynaştırılmış görüntüsünün sınıflandırılması (d) (Worldview-2 MS – Worldview-2 Pan).....	81
Şekil 32.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Brovey kaynaştırılmış görüntüsü (c), Brovey kaynaştırılmış görüntüsünün sınıflandırılması (d) (Landsat ETM+ MS – Landsat ETM+ Pan)	82
Şekil 33.	Orjinal görüntü ve Brovey kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Landsat ETM+ MS – Landsat ETM+ Pan).....	83
Şekil 34.	Orjinal görüntü ve Brovey kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Ikonos MS – Ikonos Pan).....	83
Şekil 35.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Brovey kaynaştırılmış görüntüsü (c), Brovey kaynaştırılmış görüntüsünün sınıflandırılması (d) (Ikonos MS – Ikonos Pan)	84
Şekil 36.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Brovey kaynaştırılmış görüntüsü (c), Brovey kaynaştırılmış görüntüsünün sınıflandırılması (d) (Ikonos MS – QBPan).....	84
Şekil 37.	Orjinal görüntü ve Brovey kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Ikonos MS – QBPan).....	85

Şekil 38.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Ehlers kaynaştırılmış görüntüsü (c), Ehlers kaynaştırılmış görüntüsünün sınıflandırılması (d) (Worldview-2 MS – Worldview-2 Pan).....	86
Şekil 39.	Orjinal görüntü ve Ehlers kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Worldview-2 MS – Worldview-2 Pan).....	86
Şekil 40.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Ehlers kaynaştırılmış görüntüsü (c), Ehlers kaynaştırılmış görüntüsünün sınıflandırılması (d) (Landsat ETM+ MS – Landsat ETM+ Pan)	87
Şekil 41.	Orjinal görüntü ve Ehlers kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Landsat ETM+ MS – Landsat ETM+ Pan).....	88
Şekil 42.	Orjinal görüntü ve Ehlers kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Ikonos MS – Ikonos Pan).....	88
Şekil 43.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Ehlers kaynaştırılmış görüntüsü (c), Ehlers kaynaştırılmış görüntüsünün sınıflandırılması (d) (Ikonos MS – Ikonos Pan)	89
Şekil 44.	Orjinal görüntü ve Ehlers kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Ikonos MS – QBPan).....	89
Şekil 45.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Ehlers kaynaştırılmış görüntüsü (c), Ehlers kaynaştırılmış görüntüsünün sınıflandırılması (d) (Ikonos MS – QBPan).....	90
Şekil 46.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), HPF kaynaştırılmış görüntüsü (c), HPF kaynaştırılmış görüntüsünün sınıflandırılması (d) (Worldview-2 MS – Worldview-2 Pan).....	91
Şekil 47.	Orjinal görüntü ve HPF kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Worldview-2 MS – Worldview-2 Pan).....	92
Şekil 48.	Orjinal görüntü ve HPF kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Landsat ETM+ MS – Landsat ETM+ Pan).....	92
Şekil 49.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), HPF kaynaştırılmış görüntüsü (c), HPF kaynaştırılmış görüntüsünün sınıflandırılması (d) (Landsat ETM+ MS – Landsat ETM+ Pan)	93
Şekil 50.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), HPF kaynaştırılmış görüntüsü (c), HPF kaynaştırılmış görüntüsünün sınıflandırılması (d) (Ikonos MS – Ikonos Pan)	94
Şekil 51.	Orjinal görüntü ve HPF kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Ikonos MS – Ikonos Pan).....	94
Şekil 52.	Orjinal görüntü ve HPF kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Ikonos MS – QBPan).....	95
Şekil 53.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), HPF kaynaştırılmış görüntüsü (c), HPF kaynaştırılmış görüntüsünün sınıflandırılması (d) (Ikonos MS – QBPan).....	95

Şekil 54.	Orjinal görüntü ve Multiplicative kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Worldview-2 MS – Worldview-2 Pan)	96
Şekil 55.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Multiplicative kaynaştırılmış görüntüsü (c), Multiplicative kaynaştırılmış görüntüsünün sınıflandırılması (d) (Worldview-2 MS – Worldview-2 Pan)	97
Şekil 56.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Multiplicative kaynaştırılmış görüntüsü (c), Multiplicative kaynaştırılmış görüntüsünün sınıflandırılması (d) (Landsat ETM+ MS – Landsat ETM+ Pan)	98
Şekil 57.	Orjinal görüntü ve Multiplicative kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Landsat ETM+ MS – Landsat ETM+ Pan)	98
Şekil 58.	Orjinal görüntü ve Multiplicative kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Ikonos MS – Ikonos Pan)	99
Şekil 59.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Multiplicative kaynaştırılmış görüntüsü (c), Multiplicative kaynaştırılmış görüntüsünün sınıflandırılması (d) (Ikonos MS – Ikonos Pan)	99
Şekil 60.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Multiplicative kaynaştırılmış görüntüsü (c), Multiplicative kaynaştırılmış görüntüsünün sınıflandırılması (d) (Ikonos MS – QBPan).....	100
Şekil 61.	Orjinal görüntü ve Multiplicative kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Ikonos MS – QBPan).....	101
Şekil 62.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), PCA kaynaştırılmış görüntüsü (c), PCA kaynaştırılmış görüntüsünün sınıflandırılması (d) (Worldview-2 MS – Worldview-2 Pan).....	102
Şekil 63.	Orjinal görüntü ve PCA kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Worldview-2 MS – Worldview-2 Pan).....	102
Şekil 64.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), PCA kaynaştırılmış görüntüsü (c), PCA kaynaştırılmış görüntüsünün sınıflandırılması (d) (Landsat ETM+ MS – Landsat ETM+ Pan)	103
Şekil 65.	Orjinal görüntü ve PCA kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Landsat ETM+ MS – Landsat ETM+ Pan).....	104
Şekil 66.	Orjinal görüntü ve PCA kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Ikonos MS – Ikonos Pan).....	104
Şekil 67.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), PCA kaynaştırılmış görüntüsü (c), PCA kaynaştırılmış görüntüsünün sınıflandırılması (d) (Ikonos MS – Ikonos Pan)	105
Şekil 68.	Orjinal görüntü ve PCA kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Ikonos MS – QBPan).....	105

Şekil 69.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), PCA kaynaştırılmış görüntüsü (c), PCA kaynaştırılmış görüntüsünün sınıflandırılması (d) (Ikonos MS – QBPan).....	106
Şekil 70.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Dalgacık Dönüşümü kaynaştırılmış görüntüsü (c), Dalgacık Dönüşümü kaynaştırılmış görüntüsünün sınıflandırılması (d) (Worldview-2 MS – Worldview-2 Pan).....	107
Şekil 71.	Orjinal görüntü ve Dalgacık Dönüşümü kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Worldview-2 MS – Worldview-2 Pan)	108
Şekil 72.	Orjinal görüntü ve Dalgacık Dönüşümü kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Landsat ETM+ MS – Landsat ETM+ MS Pan)	108
Şekil 73.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Dalgacık Dönüşümü kaynaştırılmış görüntüsü (c), Dalgacık Dönüşümü kaynaştırılmış görüntüsünün sınıflandırılması (d) (Landsat ETM+ MS – Landsat ETM+ Pan).....	109
Şekil 74.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Dalgacık Dönüşümü kaynaştırılmış görüntüsü (c), Dalgacık Dönüşümü kaynaştırılmış görüntüsünün sınıflandırılması (d) (Ikonos MS – Ikonos Pan)	110
Şekil 75.	Orjinal görüntü ve Dalgacık Dönüşümü kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Ikonos MS – Ikonos Pan)	110
Şekil 76.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Dalgacık Dönüşümü kaynaştırılmış görüntüsü (c), Dalgacık Dönüşümü kaynaştırılmış görüntüsünün sınıflandırılması (d) (Ikonos MS – QBPan).....	111
Şekil 77.	Orjinal görüntü ve Dalgacık Dönüşümü kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Ikonos MS – QBPan).....	111
Şekil 78.	Orjinal görüntü ve CN kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Worldview-2 MS – Worldview-2 Pan).....	112
Şekil 79.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), CN kaynaştırılmış görüntüsü (c), CN kaynaştırılmış görüntüsünün sınıflandırılması (d) (Worldview-2 MS – Worldview-2 Pan).....	113
Şekil 80.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), CN kaynaştırılmış görüntüsü (c), CN kaynaştırılmış görüntüsünün sınıflandırılması (d) (Landsat ETM+ MS – Landsat ETM+ Pan)	114
Şekil 81.	Orjinal görüntü ve CN kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Landsat ETM+ MS – Landsat ETM+ Pan).....	114
Şekil 82.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), CN kaynaştırılmış görüntüsü (c), CN kaynaştırılmış görüntüsünün sınıflandırılması (d) (Ikonos MS – Ikonos Pan)	115

Şekil 83.	Orjinal görüntü ve CN kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Ikonos MS – Ikonos Pan).....	115
Şekil 84.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), CN kaynaştırılmış görüntüsü (c), CN kaynaştırılmış görüntüsünün sınıflandırılması (d) (Ikonos MS – QBPan).....	116
Şekil 85.	Orjinal görüntü ve CN kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Ikonos MS – QBPan).....	117
Şekil 86.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Gram-Schmidt kaynaştırılmış görüntüsü (c), Gram-Schmidt kaynaştırılmış görüntüsünün sınıflandırılması (d) (Worldview-2 MS – Worldview-2 Pan)	118
Şekil 87.	Orjinal görüntü ve Gram-Schmidt kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Worldview-2 MS – Worldview-2 Pan)	118
Şekil 88.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Gram-Schmidt kaynaştırılmış görüntüsü (c), Gram-Schmidt kaynaştırılmış görüntüsünün sınıflandırılması (d) (Landsat ETM+ MS – Landsat ETM+ Pan)	119
Şekil 89.	Orjinal görüntü ve Gram-Schmidt kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Landsat ETM+ MS – Landsat ETM+ Pan) ...	120
Şekil 90.	Orjinal görüntü ve Gram-Schmidt kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Ikonos MS – Ikonos Pan)	120
Şekil 91.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Gram-Schmidt kaynaştırılmış görüntüsü (c), Gram-Schmidt kaynaştırılmış görüntüsünün sınıflandırılması (d) (Ikonos MS – Ikonos Pan)	121
Şekil 92.	Orjinal görüntü ve Gram-Schmidt kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Ikonos MS – QBPan).....	121
Şekil 93.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Gram-Schmidt kaynaştırılmış görüntüsü (c), Gram-Schmidt kaynaştırılmış görüntüsünün sınıflandırılması (d) (Ikonos MS – QBPan).....	122
Şekil 94.	Orjinal görüntü ve Kriter Tabanlı kaynaştırılmış görüntünün sınıflandırma doğrulukları (Worldview-2 MS – Worldview-2 Pan).....	123
Şekil 95.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Kriter Tabanlı kaynaştırılmış görüntü (c), Kriter Tabanlı kaynaştırılmış görüntünün sınıflandırılması (d) (Worldview-2 MS – Worldview-2 Pan).....	124
Şekil 96.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Kriter Tabanlı kaynaştırılmış görüntü (c), Kriter Tabanlı kaynaştırılmış görüntünün sınıflandırılması (d) (Landsat ETM+ MS – Landsat ETM+ Pan)	125
Şekil 97.	Orjinal görüntü ve Kriter Tabanlı kaynaştırılmış görüntünün sınıflandırma doğrulukları (Landsat ETM+ MS – Landsat ETM+ Pan).....	125
Şekil 98.	Orjinal görüntü ve Kriter Tabanlı kaynaştırılmış görüntünün sınıflandırma doğrulukları (Ikonos MS – Ikonos Pan).....	126

Şekil 99.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Kriter Tabanlı kaynaştırılmış görüntü (c), Kriter Tabanlı kaynaştırılmış görüntünün sınıflandırılması (d) (Ikonos MS – Ikonos Pan)	126
Şekil 100.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Kriter Tabanlı kaynaştırılmış görüntü (c), Kriter Tabanlı kaynaştırılmış görüntünün sınıflandırılması (d) (Ikonos MS – QBPan).....	127
Şekil 101.	Orjinal görüntü ve Kriter Tabanlı kaynaştırılmış görüntünün sınıflandırma doğrulukları (Ikonos MS – QBPan).....	128
Şekil 102.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Yeni Yöntem ile kaynaştırılmış görüntü (c), Yeni Yöntem kaynaştırılmış görüntüsünün sınıflandırılması (d) (Worldview-2 MS – Worldview-2 Pan).....	129
Şekil 103.	Orjinal görüntü ve Kriter Tabanlı kaynaştırılmış görüntünün sınıflandırma doğrulukları (Worldview-2 MS – Worldview-2 Pan).....	129
Şekil 104.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Yeni Yöntem kaynaştırılmış görüntü (c), Yeni Yöntem kaynaştırılmış görüntüsünün sınıflandırılması (d) (Landsat ETM+ MS – Landsat ETM+ Pan)	130
Şekil 105.	Orjinal görüntü ve Yeni Yöntem kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Landsat ETM+ MS – Landsat ETM+ Pan).....	131
Şekil 106.	Orjinal görüntü ve Yeni Yöntem kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Ikonos MS – Ikonos Pan).....	131
Şekil 107.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Yeni Yöntem kaynaştırılmış görüntüsü (c), Yeni Yöntem kaynaştırılmış görüntüsünün sınıflandırılması (d) (Ikonos MS – Ikonos Pan)	132
Şekil 108.	Orjinal görüntü ve Yeni Yöntem kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Ikonos MS – QBPan).....	132
Şekil 109.	Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Yeni Yöntem kaynaştırılmış görüntüsü (c), Yeni Yöntem kaynaştırılmış görüntüsünün sınıflandırılması (d) (Ikonos MS- QBPan)	133
Ek Şekil 1.	Worldview-2 MS–Worldview-2 Pan kaynaştırılmış - sınıflandırılmış görüntüler	185
Ek Şekil 2.	Landsat ETM MS – Landsat ETM Pan kaynaştırılmış – sınıflandırılmış görüntüler	188
Ek Şekil 3.	Ikonos MS – Ikonos Pan kaynaştırılmış – sınıflandırılmış görüntüler	191
Ek Şekil 4.	Ikonos MS – QBPan kaynaştırılmış – sınıflandırılmış görüntüler	194

TABLolar DİZİNİ

	<u>Sayfa No.</u>
Tablo 1.	Uygulama kapsamına kullanılan uyduların teknik özellikleri 55
Tablo 2.	Worldview-2 çok bantlı görüntüsü ile aynı uyduya ait pankromatik bandın kaynaştırılması ile elde edilen görüntülerin bantlarının ortalama ve standart sapma değerleri 60
Tablo 3.	Landsat ETM+ çok bantlı görüntüsü ile aynı uyduya ait pankromatik bandın kaynaştırılması ile elde edilen görüntülerin bantlarının ortalama ve standart sapma değerleri 61
Tablo 4.	Ikonos çok bantlı görüntüsü ile aynı uyduya ait pankromatik bandın kaynaştırılması ile elde edilen görüntülerin bantlarının ortalama ve standart sapma değerleri 61
Tablo 5.	Ikonos çok bantlı görüntüsü ile QBPan görüntüsünden elde edilen pankromatik görüntünün kaynaştırılması ile elde edilen görüntülerin bantlarının ortalama ve standart sapma değerleri 62
Tablo 6.	Worldview-2 çok bantlı görüntüsü ve pankromatik bandının kaynaştırılmasıyla elde edilen kaynaştırılmış görüntülerin bantları ile orijinal Worldview-2 görüntüsünün bantları arasındaki korelasyonlar 63
Tablo 7.	Landsat ETM+ çok bantlı görüntüsü ve pankromatik bandının kaynaştırılmasıyla elde edilen kaynaştırılmış görüntülerin bantları ile orijinal Landsat ETM+ görüntüsünün bantları arasındaki korelasyonlar 63
Tablo 8.	Ikonos çok bantlı görüntüsü ve pankromatik bandının kaynaştırılmasıyla elde edilen kaynaştırılmış görüntülerin bantları ile orijinal Ikonos görüntüsünün bantları arasındaki korelasyonlar 64
Tablo 9.	Ikonos çok bantlı görüntüsü ve QBPan görüntüsünün kaynaştırılmasıyla elde edilen kaynaştırılmış görüntülerin bantları ile orijinal Ikonos görüntüsünün bantları arasındaki korelasyonlar 65
Tablo 10.	Worldview-2 çok bantlı görüntüsü ve aynı uyduya ait pankromatik görüntünün kaynaştırılmasıyla elde edilen kaynaştırılmış görüntülerin metrik değerleri 65
Tablo 11.	Landsat ETM+ çok bantlı görüntüsü ve aynı uyduya ait pankromatik görüntünün kaynaştırılmasıyla elde edilen kaynaştırılmış görüntülerin metrik değerleri 66
Tablo 12.	Ikonos çok bantlı görüntüsü ve aynı uyduya ait pankromatik görüntünün kaynaştırılmasıyla elde edilen kaynaştırılmış görüntülerin metrik değerleri 67

Tablo 13.	İkonos çok bantlı görüntüsü ve QBPan görüntüsünün kaynaştırılmasıyla elde edilen kaynaştırılmış görüntülerin metrik değerleri	68
Ek Tablo 1.	Worldview-2 - Worldview-2 Pan kaynaştırılmış görüntüleri – iç korelasyonlar	144
Ek Tablo 2.	Landsat ETM+ - Landsat ETM+ Pan kaynaştırılmış görüntüleri - iç korelasyonlar	147
Ek Tablo 3.	İkonos - İkonos Pan kaynaştırılmış görüntüleri - iç korelasyonlar	149
Ek Tablo 4.	İkonos - QBPan kaynaştırılmış görüntüleri - iç korelasyonlar	151
Ek Tablo 5.	Orijinal görüntü ve Worldview-2 kaynaştırılmış görüntüleri için İkili Kodlama ile elde edilen kullanıcı ve üretici sınıflandırma doğrulukları ...	153
Ek Tablo 6.	Orijinal görüntü ve Worldview-2 kaynaştırılmış görüntüleri için En Yakın Mesafe ile elde edilen kullanıcı ve üretici sınıflandırma doğrulukları	154
Ek Tablo 7.	Orijinal görüntü ve Worldview-2 kaynaştırılmış görüntüleri için Maksimum Benzerlik ile elde edilen kullanıcı ve üretici sınıflandırma doğrulukları ..	155
Ek Tablo 8.	Orijinal görüntü ve Worldview-2 kaynaştırılmış görüntüleri için Yapay Sinir Ağları ile elde edilen kullanıcı ve üretici sınıflandırma doğrulukları.....	156
Ek Tablo 9.	Orijinal görüntü ve Worldview-2 kaynaştırılmış görüntüleri için Rastgele Orman ile elde edilen kullanıcı ve üretici sınıflandırma doğrulukları.....	157
Ek Tablo 10.	Orijinal görüntü ve Worldview-2 kaynaştırılmış görüntüleri için Destek Vektör Makineleri ile elde edilen kullanıcı ve üretici sınıflandırma doğrulukları.....	158
Ek Tablo 11.	Orijinal görüntü ve Landsat ETM+ kaynaştırılmış görüntüleri için İkili Kodlama ile elde edilen kullanıcı ve üretici sınıflandırma doğrulukları ...	159
Ek Tablo 12.	Orijinal görüntü ve Landsat ETM+ kaynaştırılmış görüntüleri için En Yakın Mesafe ile elde edilen kullanıcı ve üretici sınıflandırma doğrulukları	160
Ek Tablo 13.	Orijinal görüntü ve Landsat ETM+ kaynaştırılmış görüntüleri için Maksimum Benzerlik ile elde edilen kullanıcı ve üretici sınıflandırma doğrulukları.....	161
Ek Tablo 14.	Orijinal görüntü ve Landsat ETM+ kaynaştırılmış görüntüleri için Yapay Sinir Ağları ile elde edilen kullanıcı ve üretici sınıflandırma doğrulukları	162
Ek Tablo 15.	Orijinal görüntü ve Landsat ETM+ kaynaştırılmış görüntüleri için Rastgele Orman ile elde edilen kullanıcı ve üretici sınıflandırma doğrulukları.....	163
Ek Tablo 16.	Orijinal görüntü ve Landsat ETM+ kaynaştırılmış görüntüleri için Destek Vektör Makineleri ile elde edilen kullanıcı ve üretici sınıflandırma doğrulukları.....	164
Ek Tablo 17.	Orijinal görüntü ve İkonos kaynaştırılmış görüntüleri için İkili Kodlama ile elde edilen kullanıcı ve üretici sınıflandırma doğrulukları	165
Ek Tablo 18.	Orijinal görüntü ve İkonos kaynaştırılmış görüntüleri için En Yakın Mesafe ile elde edilen kullanıcı ve üretici sınıflandırma doğrulukları	166

Ek Tablo 19.	Orijinal görüntü ve İkonos kaynaştırılmış görüntüleri için Maksimum Benzerlik ile elde edilen kullanıcı ve üretici sınıflandırma doğrulukları ..	167
Ek Tablo 20.	Orijinal görüntü ve İkonos kaynaştırılmış görüntüleri için Yapay Sinir Ağları ile elde edilen kullanıcı ve üretici sınıflandırma doğrulukları.....	168
Ek Tablo 21.	Orijinal görüntü ve İkonos kaynaştırılmış görüntüleri için Rastgele Orman ile elde edilen kullanıcı ve üretici sınıflandırma doğrulukları	169
Ek Tablo 22.	Orijinal görüntü ve İkonos kaynaştırılmış görüntüleri için Destek Vektör Makineleri ile elde edilen kullanıcı ve üretici sınıflandırma doğrulukları	170
Ek Tablo 23.	Orijinal İkonos ve QBPan görüntülerinin kaynaştırılması ile elde edilen görüntülerin İkili Kodlama sınıflandırıcısı ile sınıflandırılmasıyla elde edilen kullanıcı ve üretici doğrulukları.....	171
Ek Tablo 24.	Orijinal İkonos ve QBPan görüntülerinin kaynaştırılması ile elde edilen görüntülerin En Yakın Mesafe sınıflandırıcısı ile sınıflandırılmasıyla elde edilen kullanıcı ve üretici doğrulukları	172
Ek Tablo 25.	Orijinal İkonos ve QBPan görüntülerinin kaynaştırılması ile elde edilen görüntülerin Maksimum Benzerlik sınıflandırıcısı ile sınıflandırılmasıyla elde edilen kullanıcı ve üretici doğrulukları	173
Ek Tablo 26.	Orijinal İkonos ve QBPan görüntülerinin kaynaştırılması ile elde edilen görüntülerin Yapay Sinir Ağları sınıflandırıcısı ile sınıflandırılmasıyla elde edilen kullanıcı ve üretici doğrulukları	174
Ek Tablo 27.	Orijinal İkonos ve QBPan görüntülerinin kaynaştırılması ile elde edilen görüntülerin Rastgele Orman sınıflandırıcısı ile sınıflandırılmasıyla elde edilen kullanıcı ve üretici doğrulukları	175
Ek Tablo 28.	Orijinal İkonos ve QBPan görüntülerinin kaynaştırılması ile elde edilen görüntülerin Destek Vektör Makineleri sınıflandırıcısı ile sınıflandırılmasıyla elde edilen kullanıcı ve üretici doğrulukları	176
Ek Tablo 29.	Landsat ETM+ kaynaştırılmış görüntülerinin sınıflandırılması ile elde edilen Kappa değerleri.....	177
Ek Tablo 30.	Worldview-2 kaynaştırılmış görüntülerinin sınıflandırılması ile elde edilen Kappa değerleri.....	179
Ek Tablo 31.	İkonos kaynaştırılmış görüntülerinin sınıflandırılması ile elde edilen Kappa değerleri	181
Ek Tablo 32.	İkonos – QBPan kaynaştırılmış görüntülerinin sınıflandırılması ile elde edilen Kappa değerleri	183

SEMBOLLER DİZİNİ

AA	: Alçak-Alçak
ALI	: Advanced Land Imager
AY	: Alçak-Yüksek
BE	: Binary Encoding (İkili Kodlama)
Bit	: Binary Digit
BR	: Brovey
CN	: Color Normalized
Cos	: Cosinus
Cov	: Covariance
DÇP	: Düşük Çözünürlüklü Pankromatik Görüntü
DD	: Dalgacık Dönüşümü
DVM	: Destek Vektör Makineleri
EH	: Ehlers
ENVI	: Environment for Visualizing Images
EO	: Earth Observation
ERGAS	: Erreur Relative Globale Adimensionnelle de Synthèse
ETM	: Enhanced Thematic Mapper
exp	: exponansiyel
EYM	: En Yakın Mesafe
FFT	: Fast Fourier Transformation
GD	: Geometrik Dönüşüm
GS	: Gram-Schmidt
HPF	: High Pass Filter
IHS	: Intensity-Hue-Saturation
ISODATA	: The Iterative Self-Organizing Data Analysis Technique
KÖ	: Kızılötesi
KT	: Kriter Tabanlı Görüntü Kaynaştırma Yöntemi
KYM	: Kırmızı-Yeşil-Mavi
ln	: logarithm natural

log	: logaritma
LR	: Learning Rate
MATLAB	: Matrix Laboratory
MB	: Maksimum Benzerlik
min	: minimum
MS	: Multispectral/Multispektral
MUL	: Multiplicative
nm	: nanometre
OG	: Optik Geçirgenlik
ORJ	: Orijinal Görüntü
Pan	: Pankromatik
PCA	: Principal Component Analysis
RASE	: Relative Average Spectral Error
RGB	: Red-Green-Blue
RMS	: Karesel Ortalama Hata
RMSE	: Root Mean Squared Error
RO	: Rastgele Orman
SAM	: Spectral Angular Mapper
SD	: Spectral Distance
SID	: Spectral Information Divergence
SPOT	: Système Pour l'Observation de la Terre
SR	: Spectral Response
SVR	: Synthetic Variable Ratio
tanh	: Tanjant Hiperbolik
VC	: Vapnik-Chervonenkis
WV2	: Worldview-2
YA	: Yüksek-Alçak
YSA	: Yapay Sinir Ağları
YÜY	: Yüksek-Yüksek
YY	: Yeni Yöntem

1. GENEL BİLGİLER

1.1. Giriş

Uzaktan algılama, yeryüzündeki cisimlere temas etmeksizin onlar hakkında bilgi toplama bilimidir. Bilgi toplama işlemi gökyüzündeki uydular veya bazı başka hava araçları yardımıyla gerçekleştirilir. Bu araçlar, yeryüzündeki nesnelere yansıyan elektromanyetik enerjiyi algılar ve uzaktan algılanmış görüntü oluşturulur. Son yıllarda uzaktan algılama bilimi oldukça ön planda olup, birçok disiplin tarafından sıklıkla kullanılmaktadır. Ortofoto görüntülerin üretilmesi, sayısal arazi modeli üretimi, yeryüzündeki deformasyonların izlenmesi, değişim analizleri, bitki örtüsü analizleri, şehir ve bölge planlama, ağaçlandırma çalışmaları, orman kaynakları envanterinin belirlenmesi, orman yönetimi, çölleşme izleme ve araştırmaları, jeolojik çalışmalar, deniz, göl ve akarsuların kirlilik analizleri gibi kullanım alanları bunlardan bazılarıdır (URL-1).

Uzaktan algılama yöntemiyle elde edilen uydu görüntüleri dijital ortamda olduklarından sayısallaştırma işleminin gerekliliği ortadan kalkmaktadır. Aynı zamanda bu görüntüler Coğrafi Bilgi Sistemleri ile kolaylıkla bütünleşebilir. Bunun yanında uydu görüntüleri insan gözünün göremediği olguları görüntüleyebildiği için yeryüzünün incelenmesi konusunda oldukça faydalıdır. Görüntü işleme teknikleri yeryüzü hakkında birçok verinin hızlı ve doğru bir biçimde elde edilmesine olanak sağlar. Ayrıca bu teknikler sayesinde ulaşılmak istenilen amaca yönelik olarak yeryüzü ile ilgili birçok konumsal analiz gerçekleştirilebilir. Elde edilen veriler tasarlanan Coğrafi Bilgi Sistemleri veri tabanlarında depolanarak birçok uygulama için analizler yapılmasına ve arazi yönetimi için kararlar alınmasına olanak sağlamaktadırlar (Koç ve Yener, 2001).

Teknolojinin gelişmesiyle birlikte zamanla daha yüksek konfigürasyonlu uydular gökyüzüne fırlatılmaktadır. Dolayısıyla gün geçtikçe daha yüksek konumsal ve spektral çözünürlüklü uydu görüntüleri elde edilmektedir. Uydu görüntüleri yardımıyla yeryüzü hakkında bilgi toplanması zaman ve maliyet bakımından yersel tekniklere göre çoğu zaman daha avantajlıdır. Uydu görüntüleri kullanılarak oldukça geniş alanlar hakkında veriler kısa sürede elde edilebilirken bu durum yersel teknikler için söz konusu değildir.

Uzaktan Algılama ile elde edilen görüntüler yeryüzü ile ilgili birçok bilgiyi kullanıcıya sunar. Bu bilgiler yeryüzündeki nesnelere yansıtılarak gelen elektromanyetik

enerjinin algılayıcı sensörler tarafından algılanarak çeşitli bantlara kaydedilmesi ile elde edilir (Tarhan, 2004). Eğer elektromanyetik enerji tek bir bant tarafından toplanıyorsa bu görüntülere tek bantlı (pankromatik) görüntüler denir. Tek bantlı görüntülerde elektromanyetik spektrumun görünür bölümü ile kızılötesi bölümü kullanılır ve bu tür görüntüler siyah beyazdır. Elektromanyetik enerjinin birkaç farklı bant tarafından toplanılması durumunda ise çok bantlı (multispektral) görüntüler elde edilir. Çok bantlı görüntüler elektromanyetik spektrumun $\sim 400 - 1000$ nm aralığında gelen enerjiyi farklı bantlarda toplar. Çok bantlı görüntüler kullanım amaçlarına göre farklı kombinasyonlarda bir araya getirilebilir. Bu özellikleri ile çok bantlı görüntüler yeryüzündeki nesnelere ayırt edebilmede tek bantlı görüntülere oranla çok daha avantajlıdır. Hiper bantlı görüntülerde ise bant sayısı çok bantlı görüntülere oranla çok daha fazladır. Hiper bantlı görüntülerdeki bant sayılarının alt ve üst limiti hakkında kabul görmüş birer sayı bulunmamaktadır. Örneğin EO1 uydusunun Hyperion sensörü kalibre edilmemiş bantlarla birlikte toplam 242 bantlı görüntü üretmektedir.

Konumsal çözünürlüğü yüksek olan bir görüntüdeki konumsal detayların konumsal çözünürlüğü düşük olan görüntülere transfer edilmesi işleme görüntü kaynaştırma denir. Farklı görüntü kaynaştırma yöntemleri farklı sonuçlar vermektedir. Bazı görüntü kaynaştırma yöntemleri yüksek konumsal çözünürlüklü görüntüdeki detayları daha düşük konumsal çözünürlüklü görüntüye aktarırken düşük konumsal çözünürlüklü görüntünün spektral yapısını bozmaktadır. Öte yandan, bazı kaynaştırma yöntemleri ise düşük konumsal çözünürlüklü görüntünün spektral yapısını korurken yüksek konumsal çözünürlüklü görüntüye ait detayları gerektiği gibi aktaramamaktadır. Literatürde kaynaştırılan görüntülerin konumsal ve spektral kalitelerinin belirlenmesi amacıyla tanımlanan bazı metrikler bulunmaktadır. Bu metriklerden Relative Average Spectral Error (RASE), Erreur Relative Globale Adimensionnelle de Synthèse (ERGAS), Root Mean Square Error (RMSE), Spectral Angular Mapper (SAM) ve Spectral Information Divergence (SID) metrikleri bu çalışma kapsamına spektral ve konumsal kalite ölçümü için kullanılmıştır. Bu metriklerin birtakım avantajlarının yanında bazı dezavantajları da bulunmaktadır. RMSE metriği her bir pikseldeki değişim miktarını hesaplarken kaynaştırmada kullanılan görüntülerin çözünürlük farkını hesaba katmaz (Gungor, 2008). RASE metriği de kaynaştırılmış görüntünün spektral kalitesini ölçmeye yarayan bir başka metriktir. Ancak bu metrik de RMSE metriği gibi çözünürlük farkını dikkate almaz. ERGAS metrikleri ise RMSE ve RASE metriklerinin aksine kaynaştırmada kullanılan

görüntülerin çözünürlüklerini kullanır (Gungor, 2008). ERGAS metrikleri orijinal görüntü ve kaynaştırılmış görüntülerin ortalamalarındaki farklılıkları dikkate alarak görüntüdeki radyometrik distorsiyonları da belirler. ERGAS metriklerinin dezavantajı ise kaynaştırılmış görüntü ve orijinal çok bantlı görüntü arasındaki korelasyonları hesaba katmamasıdır. SAM metriği de kaynaştırılmış görüntüdeki spektral kaliteyi ölçmeye yarar fakat bu yöntem orijinal görüntü ve kaynaştırılmış görüntülerin ortalamalarındaki, standart sapmalarındaki ve konumsal çözünürlüklerindeki farklılıkları göz ardı eder (Gungor, 2008). SID metriği SAM metriğinin geliştirilmiş halidir. Ancak SID metriği de SAM metriğinin dezavantajlarına sahiptir. Bu metrikler bu gibi dezavantajlarından dolayı her zaman sağlıklı sonuçlar veremeyebilmektedirler. Dolayısıyla bu gibi metriklerin yanı sıra kaynaştırılmış görüntülerin sınıflandırma performanslarının incelenmesi görüntü kaynaştırma işlemlerinin başarısını ölçme açısından faydalı olacaktır.

Bu çalışmada kentsel alanlarından, kırsal alanlardan ve kentsel alanlar ile kırsal alanların bir arada bulunduğu bölgelerden alınan görüntülerin kaynaştırılmasıyla elde edilen kaynaştırılmış görüntülerin sınıflandırma performansına etkilerinin incelenmesi amaçlanmıştır. Kentsel alanlar için pilot bölge olan Trabzon ilinin kent merkezine ait Ikonos çok bantlı görüntüsü kendi pankromatik bandıyla ve aynı bölgeye ait başka bir Ikonos görüntüsü Quickbird pankromatik görüntüsü ile pankromatik görüntüsünden elde edilen pan kaynaştırılmıştır. Kırsal alanlar için ise Trabzon ilinin Sürmene ilçesine ait Landsat ETM+ çok bantlı görüntüsü kendi pankromatik bandıyla, kentsel ve kırsal alanların bir arada bulunduğu bölge için ise yine Trabzon ilinin Sürmene ilçesine ait Worldview-2 çok bantlı görüntüsü kendi pankromatik bandıyla kaynaştırılmıştır. Kullanılan kaynaştırma yöntemleri Ehlers, Gram-Schmidt, CN, IHS, HPF, PCA, Multiplicative, Brovey, Dalgacık Dönüşümü, Kriter Tabanlı Görüntü Kaynaştırma yöntemi ve literatürdeki yeni bir görüntü kaynaştırma yöntemidir. Kaynaştırılan görüntüler sınıflandırılıp kıyaslanarak sınıflandırma doğruluğuna hangi görüntü kaynaştırma yöntemlerinin nasıl etki ettiği araştırılmıştır. Sınıflandırma aşamasında kullanılan sınıflandırma yöntemleri ise En Yakın Mesafe, İkili Kodlama, Destek Vektör Makineleri, Rastgele Orman, Maksimum Benzerlik ve Yapay Sinir Ağları algoritmalarıdır.

1.2. Problemin Tanımı

Spektral çözünürlük görüntüdeki bantların hangi dalga boyu aralığına duyarlı olduklarının ölçütüdür. Uydu görüntülerinin spektral çözünürlükleri yeryüzündeki nesnelere birbirlerinden ayırt edilebilmesinde oldukça önemlidir. Ne kadar fazla sayıda banda sahip uydu görüntüsü kullanılırsa nesnelere birbirlerinden o kadar iyi ayrılabilir. Fakat uydu görüntülerindeki bant sayısı arttıkça her bir banda düşen elektromanyetik enerji miktarı düşmektedir. Enerji kaybının önüne geçebilmek için daha büyük boyutta sensörler tarafından elektromanyetik enerji toplanır. Bu durumda da yer örnekleme aralığı arttığından dolayı konumsal çözünürlük düşmektedir. Bu problemin çözümü görüntü kaynaştırma ile mümkündür. Görüntü kaynaştırma veya bir diğer adıyla görüntü füzyonu (image fusion), yüksek konumsal çözünürlüklü bir görüntüdeki konumsal detayların düşük konumsal çözünürlüklü bir görüntüye aktararak yüksek konumsal çözünürlüklü yeni bir görüntü elde edilmesi işlemidir. Görüntü kaynaştırma yöntemi ile görüntülerin yorumlanabilirlikleri daha da artmaktadır. Ancak görüntü kaynaştırmanın dezavantajı görüntülerde spektral bozulmalara neden olmasıdır. Spektral yapısı bozulmuş görüntüler sınıflandırıldıklarında istenilen sınıflandırma doğruluklarını veremeyebilmektedirler.

1.3. Çalışmanın Amacı

Bu çalışmada seçilen pilot bölgelere ait Worldview-2, Ikonos ve Landsat ETM+ çok bantlı görüntülerinin kendi pankromatik bantlarıyla, başka bir Ikonos görüntüsünün ise Quickbird pankromatik bandıyla değişik kaynaştırma yöntemleri kullanılarak kaynaştırılması ve elde edilen kaynaştırılmış görüntülerin farklı yöntemlerle sınıflandırılarak kaynaştırma yöntemlerinin sınıflandırma performansına nasıl etki ettiklerinin incelenmesi amaçlanmıştır.

1.4. Metodoloji

Bu yüksek lisans tezi kapsamında gerçekleştirilen uygulamalarda izlenen adımlar aşağıdaki gibidir:


- Seçilen pilot bölgelere ait Ikonos, Landsat ETM+ ve Worldview-2 çok bantlı görüntülerinin kendi pankromatik bantları ile, başka bir Ikonos görüntüsünün ise Quickbird pan-sharpened görüntüsüyle (QBPan) 1.1 bölümünde bahsedilen 11 farklı görüntü kaynaştırma yöntemine göre kaynaştırılması.
- Kaynaştırılan görüntülerin 1.1 bölümünde bahsedilen 6 farklı sınıflandırma algoritmasına göre sınıflandırılması.
- Elde edilen sınıflandırma sonuçlarının değerlendirilerek hangi sınıfın veya sınıfların hangi sınıflandırma yöntemlerinde daha başarılı/başarısız olduklarının yorumlanması.
- Kaynaştırılmış görüntülerin spektral ve konumsal kalitelerinin belirlenmesinde kullanılan birtakım metriklerin ve istatistikî verilerin hesaplanması ve hesaplanan bu verilerle sınıflandırma sonuçlarının karşılaştırılması.
- Spektral yapıya en az zarar veren kaynaştırma yönteminin bu çalışma kapsamında kullanılan görüntülere göre hangisi olduğunun belirlenmesi.

1.5. Görüntü Kaynaştırma

Her bir uydu görüntüsü konumsal ve spektral bilgiler içermektedir. Uzaktan algılama biliminde konumsal çözünürlük bir görüntüdeki her bir pikselin arazideki kapladığı alanı göstermektedir. Spektral çözünürlük ise bir görüntünün bantlarının farklı dalga boyu aralıklarını birbirinden ayırabilme yeteneğini tanımlar. Bir başka deyişle görüntüdeki bant sayısı o görüntünün spektral çözünürlüğünü belirler. Uyduların üretimi aşamasında her bir spektral bant elektromanyetik spektrumun belirli bir bölgesini algılayabilmek için üretilmiştir (Yomralıoğlu, 2005).

Uydu görüntülerinin bant sayısının fazla sayıda olması benzer spektral özellikte olan nesnelerin birbirlerinden daha kolay ayrılmasına olanak verir. Ayrıca, yeryüzündeki nesnelerin birbirlerinden ayırt edilebilmesinin yanında konumlarının da hassas olarak belirlenmesi oldukça önemlidir. Fakat her zaman yüksek konumsal çözünürlüğe sahip olan


çok bantlı veya hiper bantlı görüntüler elde edilemeyebilir. Bu gibi durumlarda konumsal çözünürlüğü arttırmak amacıyla görüntü füzyonu kullanılır. Yüksek konumsal çözünürlüklü görüntüdeki konumsal detaylar çeşitli algoritmalarla faydalanılarak düşük konumsal çözünürlüklü uydu görüntüsüne transfer edilir. Yeni oluşan görüntünün konumsal çözünürlüğü füzyonda kullanılan yüksek konumsal çözünürlüklü görüntüyle aynı olur. Görüntü kaynaştırma işlemi gerçekleştirilirken düşük konumsal çözünürlüğe sahip olan görüntünün spektral yapısının mümkün olduğunca korunmasına dikkat edilmelidir.



Şekil 1. Görüntü kaynaştırma (Abas, 2011).

1.5.1. Görüntü Kaynaştırmada Dikkat Edilmesi Gereken Hususlar

Görüntü kaynaştırma işlemi gerçekleştirilirken spektral yapının korunamamasının birtakım nedenleri vardır. Örneğin Şekil 2’deki gibi bir Ikonos pankromatik görüntüsü ile ALI çok bantlı görüntüsü kaynaştırılmak istendiğinde kaynaştırma sonucu elde edilen görüntüde renk bozulmaları kaçınılmazdır. Çünkü Ikonos pankromatik görüntüsü elektromanyetik spektrumun 450 – 900 nm dalga boyu aralığında gelen enerjiden elde edilirken ALI görüntüsü 480 – 690 nm aralığından elde edilir. Dalga boyu aralıklarındaki bu farklılıklar gri değerlerde değişimlere neden olmaktadır. Görsel olarak da her iki pankromatik görüntü incelendiğinde görüntüler arasındaki renk farklılıkları göze çarpmaktadır. Ikonos görüntüsünde renkler genel manada daha parlak iken ALI görüntüsünde daha koyu ve mattır. Bu nedenden dolayı aynı sensörden toplanan çok bantlı bir görüntü ile pankromatik görüntünün kaynaştırılmasında elde edilen başarı farklı sensörlerden toplanan görüntülerin kaynaştırılmasında elde edilecek olan başarıdan daha fazladır. Bunların yanı sıra görüntü kaynaştırmada kullanılacak olan pankromatik görüntü ile çok bantlı görüntünün birbirlerine yakın zamanlarda çekilmiş olması da önem arz etmektedir. Eğer çok farklı zamanlarda çekilen iki görüntü kaynaştırılıyorsa bir görüntüde bulunan detaylar başka bir görüntüde olamayabileceği için görüntü kaynaştırmanın başarısı düşebilir. Kaynaştırılacak görüntülerin spektral yapılarının mümkün olduğunca birbirlerine benzemesi oldukça önemlidir.



Şekil 2. Aynı bölgeye ait ALI (solda) ve Ikonos (sağda) pankromatik görüntüleri

Görüntü kaynaştırma işleminde sonuç görüntüsüne etki edebilecek olan bir diğer önemli etken de kaynaştırılacak olan görüntülerin projeksiyon ve koordinat bilgileridir. Kaynaştırılacak olan her iki görüntü de aynı koordinat sistemine sahip olmasalar bile tamamıyla üst üste binecek şekilde olmalıdırlar. Aksi takdirde elde edilecek olan sonuç görüntüsünde kayıklıklar olacak, bu da yanlış sonuç elde edilmesine yol açacaktır. Dolayısıyla görüntü kaynaştırma işleminden önce kaynaştırılacak olan her iki görüntünün üst üste çakıştığından emin olunmalı, eğer değilse dönüşüm ile her iki görüntü üst üste oturtulmalıdır. Kaynaştırılacak olan görüntülerin hassas bir şekilde aynı koordinat sistemine oturtulması kaynaştırma işleminin doğruluğunu arttırmanın yanı sıra bir sonraki sınıflandırma aşamasında da elde edilecek olan hassasiyeti doğrudan arttıracaktır. Kaynaştırılmış görüntüdeki konumsal çözünürlük çok bantlı görüntüye oranla artacağından, bu görüntü üzerinden arazideki sınıfları tanıtmak amacıyla kullanılacak olan imzaların (signature) toplanması da kolaylaşacaktır. Bu çalışmanın esas amacı en faydalı kaynaştırma yöntemini kaynaştırılmış görüntülerin kontrollü sınıflandırma performansları yardımıyla belirlemek olduğundan imzaların doğru şekilde seçilmesi büyük rol oynamaktadır. İmzaların doğru şekilde toplanabilmesi de görüntüdeki koordinat bilgisine bağlıdır.

Görüntü kaynaştırma işleminde kaynaştırılacak olan görüntülerin satır ve sütun sayılarının aynı olması önemlidir. Bu yüzden genellikle çok bantlı görüntülerin boyutları pankromatik görüntülerin boyutlarına eşitlenir. Bu işleme “upsampling” denilmektedir. Bu işlem en yakın mesafe, bilinear, bikübik vb. gibi yeniden örnekleme yöntemlerinden birine göre gerçekleştirilir. En yakın mesafe yönteminde bir pikselin yeni gri değeri çevredeki piksellerden en yakın olanının gri değeri olarak belirlenir. Diğer yöntemler pikselin yeni gri değerini belirlemek için çevredeki piksellerin gri değerlerini birtakım hesaplamalar ile belirler. Bu yeniden örnekleme yöntemleri bir sonraki bölümde daha detaylı olarak algoritmalarıyla birlikte açıklanmıştır. Bu çalışmada yeniden örnekleme metodu olarak en yakın mesafe yöntemi kullanılmıştır. Bunun nedeni diğer yöntemlerin çok bantlı görüntünün renk yapısında daha fazla değişikliklere neden olabilmeleridir.


1.5.2. Ön İşleme (Preprocessing)

Uzaktan algılanmış görüntüler kullanılmadan önce bir takım düzeltmelere ve iyileştirmelere ihtiyaç duyarlar. Bu düzeltmeler sayesinde görüntüler yapılarındaki hatalardan kurtulurlar. Görüntüler işlenmeden önce bu tip hataların giderilmesine ön işleme denilir. Ön işleme aşamasında görüntülerin atmosferik ve geometrik hataları düzeltilir.

1.5.2.1. Geometrik Düzeltme

Uzaktan algılanmış görüntülerde algılayıcının konumundan, yüksekliğinden, hızından, yeryüzü eğriliğinden veya atmosferik kırılmadan dolayı bir takım geometrik hatalar oluşabilmektedir. Geometrik düzeltmenin amacı uydu verilerini haritanın geometrik özelliklerine sahip bir projeksiyon sisteminde elde etmektir (Sunar ve Kaya, 1996). Geometrik hataların giderilmesi amacıyla hem görüntüde hem de arazide ortak bulunan kontrol noktaları kullanılır. Görüntü işleme yazılımları vasıtasıyla arazideki koordinatı bilinen noktalar ile bu noktaların görüntüdeki karşılıkları işaretlenir. İşaretlenen bu noktalar yardımıyla görüntü koordinatları ile arazi koordinatları arasında ilişkiyi belirleyen denklemler kurulur. Elde edilen denklemler çözülerek görüntüdeki geometrik bozuklukların giderilmesi ve her iki görüntünün de aynı koordinat sistemi üzerinde olması sağlanmaktadır. Bu şekilde arazideki koordinatları bilinen noktalardan faydalanılarak geometrik bozuklukların giderilmesi işlemine *rektifikasyon* denir. Arazide koordinatları bilinen kontrol noktaları kullanmak yerine bir koordinat sistemine sahip olan başka bir görüntü yardımıyla da geometrik düzeltme gerçekleştirilebilir. Şöyle ki, geometrik olarak düzeltilmesi istenen görüntü ile önceden tanımlı bir koordinat sistemine sahip olan görüntü üzerinde ortak kontrol noktaları (bina köşesi, yol kesişimleri vb.) belirlenir ve her iki görüntü arasında ilişki kurulur. Rektifikasyon işlemine benzer şekilde elde edilen denklemler çözülür ve görüntüye tanımlı bir koordinat sistemi kazandırılmış olunur. Bu durumda olduğu gibi bir görüntü kullanarak başka bir görüntüdeki geometrik bozuklukların giderilmesi işlemine *registrasyon (registration)* denir.

Doğru bir geometrik düzeltme işlemi gerçekleştirebilmek için yer kontrol noktaları güvenilir noktalar olmalı, bunun yanında bu noktaların görüntünün bir bölgesinde toplanmasından ziyade görüntü üzerinde dağılımlarına dikkat edilmelidir. Aksi takdirde görüntünün her bölgesi eşit doğrulukta koordinatlandırılmaz.



Şekil 3. Geometrik düzeltme (Gonzales and Woods, 2003).

Rektifikasyon veya registrasyon işlemlerinde geometrik düzeltme uygulanacak görüntü ile ilişki kurmak için farklı dönüşüm yöntemleri mevcuttur. En çok kullanılan dönüşüm yöntemlerinden biri Affine dönüşümdür. Bu dönüşüme göre en az üç tane kontrol noktasından faydalanılarak dönüşüm gerçekleştirilir.

Geometrik düzeltmede dönüşümden sonra elde edilen koordinatlarla dönüşümde kullanılan koordinat sistemi arasında uyum sağlanamıyorsa dönüşümde bir hata vardır. Bu dönüşüm hatası bir yer kontrol noktası ile o noktanın dönüşümden sonraki konumu arasındaki uzaklıktır. Bu uzaklığa karesel ortalama hata (RMS) denilir. Uzaktan algılanmış görüntülere Geometrik Dönüşüm (GD) uygulandığında RMS hatası görüntünün piksel boyutunun yarısı kadar olmalıdır (Welch and Ustary, 1984). Örneğin 30 m konumsal çözünürlüklü Hyperion görüntüsüne geometrik dönüşüm uygulandığında RMS hatası 15 m' den az olmalıdır. Karesel ortalama hata formülü;

$$RMS = \sqrt{R_x^2 + R_y^2} \quad (1)$$

şeklindedir. Bu formüldeki R_x ve R_y sırasıyla X ve Y yönündeki karesel ortalama hatalar olup, formülleri şu şekildedir;

$$R_x = \sqrt{\frac{1}{n} \sum_{i=1}^n XR_i^2}$$

$$R_y = \sqrt{\frac{1}{n} \sum_{i=1}^n YR_i^2}$$
(2)

Bu formüllerdeki *RMS* toplam karesel ortalama hatayı, i 'inci yer kontrol noktasını, XR_i i 'inci yer kontrol noktasının X yönündeki gerçek hatasını ve YR_i ise i 'inci yer kontrol noktasının Y yönündeki gerçek hatasını göstermektedir.

Geometrik düzeltme ile görüntü bir koordinat sistemine oturtulduktan sonra görüntünün piksellerine de yeni gri değerler atanmalıdır. Bu işleme yeniden örnekleme denir. En sık kullanılan yeniden örnekleme yöntemleri en yakın komşu, bilineer enterpolasyon ve bikübik yeniden örnekleme yöntemidir.

En Yakın Komşu Yöntemi: Oldukça basit bir yöntemdir. Bu yöntemde yeni piksel konumuna en yakın gri değer yeni gri değer olarak atanır.

Bilineer Enterpolasyon Yöntemi: Bu yöntemde gri değeri hesaplanacak olan noktayı çevreleyen en yakın 4 noktanın gri değerleri ve bu noktaya olan uzaklıkları kullanılarak yeni gri değer hesaplanır.

$$GD_P = \frac{\sum_{k=1}^4 \frac{Z_k}{D_k^2}}{\sum_{k=1}^4 \frac{1}{D_k^2}}$$
(3)

Burada GD_P yeni gri değeri, Z_k çevredeki noktaların gri değerlerini ve D_k ise hesaplanan noktadan çevredeki 4 noktaya olan mesafeleri göstermektedir.

Bikübik Yeniden Örnekleme Yöntemi: Bu yöntem bilineer enterpolasyon yöntemine çok benzer fakat bu yöntemde söz konusu pikselin çevresindeki 16 nokta kullanılır.

$$GD_P = \frac{\sum_{k=1}^{16} \frac{Z_k}{D_k^2}}{\sum_{k=1}^{16} \frac{1}{D_k^2}} \quad (4)$$

Burada GD_P yeni gri değeri, Z_k çevredeki noktaların gri değerlerini ve D_k ise hesaplanan noktadan çevredeki 16 noktaya olan mesafeleri göstermektedir.

1.5.2.2. Radyometrik Düzeltme

Uzaktan algılama işlemi gerçekleştirilirken verinin alınması veya başka bir yere transferi sırasında görüntüde meydana gelen bozukluklardır. Bu tür bozukluklar verinin gri değerlerinde anormallik ortaya çıkarabilir. Sensörden kaynaklanan hatalardan bir tanesi kayıp satır hatasıdır. Bu hata çeşidinde görüntü toplanırken hatalı veya kayıp satırlar oluşmaktadır. Bu hatanın en yaygın çözümü bozuk olan satırdan bir önceki satır ile bir sonraki satırın ortalamasını alıp sonucu bozuk olan satırın yerine koymaktır. Bu hatanın bir başka çeşidi de “De-Striping” hatasıdır. Bu hata çeşidinde ise görüntüde belirli aralıklarda yanlış veya eksik satırlar bulunmaktadır. Şekil 4’ de bu hataya bir örnek gösterilmektedir. Sensörden kaynaklanan bir başka hata ise bit hatasıdır. Bu hatanın nedeni ise çevresindeki piksellerin gri değerlerine göre bazı piksellerin yüksek veya düşük değere sahip olmasıdır. Bu tür hataların giderilmesinin yolu da hatalı olan pikselin çevresindeki piksellerin ortalaması ile yer değiştirmesidir. Radyometrik bozulmaların nedenleri böyle teknik nedenlerin haricinde atmosferik nedenler de olabilir. Elektromanyetik enerji yeryüzündeki nesnelere yansıtılarak algılayıcıya gelirken atmosferde su buharı, toz, gaz molekülleri, sis veya pus gibi birtakım engellerle karşılaşabilir. Bu gibi etkilerle karşılaşan elektromanyetik enerjinin yoğunluğunda ve kat ettiği mesafede değişiklikler olacağından elektromanyetik enerji tamamıyla algılayıcıya ulaşamaz. Radyometrik hatalar genellikle sistematik hatalar olup, çoğu zaman modellenerek çözülebilmektedirler.



Şekil 4. De-striping hatası (URL-2).

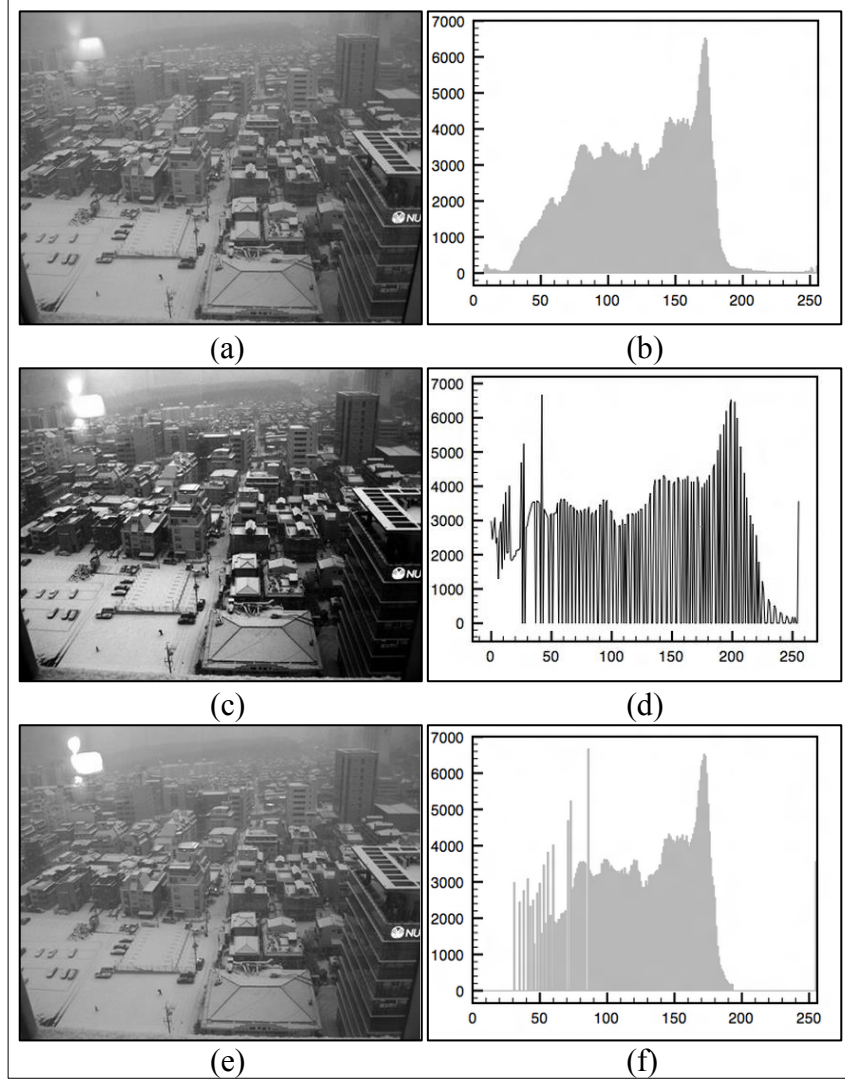
1.5.2.3. Histogram Eşleme (Histogram Matching)

Bir görüntünün histogramını başka bir görüntünün histogramına benzetmeye histogram eşleme denir. 1.5.3.1 bölümünde değinilen IHS dönüşümü ile görüntü kaynaştırma işleminde IHS dönüşümü ile elde edilen I bileşeninin kaynaştırmada kullanılacak olan pankromatik görüntüye konumsal çözünürlüğü hariç eşit olduğu varsayımı yapılmaktadır. Bu varsayımdan yola çıkılarak bu iki görüntünün aynı atmosferik koşullarda ve aynı ışık ortamında çekilmiş olması gerekir. Kullanılacak olan I bileşeninin histogramı pankromatik görüntünün histogramına eşlenir ve daha sonrasında I bileşeni ile pankromatik görüntü yer değiştirir. Benzer bir durum da PCA dönüşümü yöntemi ile görüntü kaynaştırma için geçerlidir. Bu yöntemde de temel bileşenler dönüşümü ile elde edilen 1. temel bileşen pankromatik görüntü ile yer değiştireceğinden bu görüntünün histogramının pankromatik görüntünün histogramına mümkün olduğunca benzer olması yöntemin daha sağlıklı sonuç vermesi açısından faydalıdır.

Görüntü kaynaştırmadan önce histogram eşleme yapılması görüntü kaynaştırma işleminin sonucuna genellikle olumlu yönde etki yapmaktadır. Histogram eşleme işleminin başarılı olabilmesi için histogramları eşlenecek olan görüntülerin histogram eğrileri şekil olarak birbirine benzemeli ve her iki görüntüdeki arazi sınıflarının dağılımı yaklaşık olarak aynı olmalıdır.

Şekil 5' de histogram eşleme uygulamasına bir örnek verilmiştir. Şekil 5.a' da örnek görüntü, 5.b' de örnek görüntüye ait histogram, 5.c' de histogramı Şekil 5.a' da gösterilen görüntüye eşlenmek istenilen görüntü, 5.d' de bu görüntüye ait histogram, 5.e' de

histogramı eşlenmiş görüntü ve 5.f’ de ise histogramı eşlenmiş görüntünün yeni histogramı gösterilmektedir. Bu görüntüler incelendiğinde histogram eşleme işleminden sonra elde edilen yeni görüntünün (Şekil 5.e) renk yapısının ana görüntüye (Şekil 5.a) olan benzerliği dikkat çekmektedir.



Şekil 5. Histogram eşleme (URL-3).

1.5.3. Görüntü Kaynaştırma Yöntemleri

1.5.3.1. IHS (Intensity – Hue - Saturation) Dönüşümü ile Görüntü Kaynaştırma

IHS renk uzayında renkler I (intensity - yoğunluk), H (hue - ton) ve S (saturation - renksel doygunluk) olmak üzere üç bileşenle temsil edilir. Bu bileşenler görseldir ve insanlar tarafından yorumlanmaya oldukça müsaittir. Bir renkten diğer bir renge geçiş bu renk uzayında oldukça kolaydır. Birçok görüntü işleme yazılımında bu renk uzayı kullanılmaktadır. Yoğunluk bileşeni rengin parlaklığını ifade eder. Görüntünün siyaha veya beyaza ne kadar yakın olduğunu gösterir. Yorumlanabilir ve ölçülebilir bir fiziksel niceliktir (Gonzales and Woods, 2003). Ton bileşeni gördüğümüz renklerdeki baskın dalga boyudur (Mather, 1999). Örneğin bir limona sarı dediğimizde onun ton bileşeninden bahsetmiş oluruz. Renksel doygunluk bileşeni ise bir rengin beyaz ışık ile ne kadar seyreltilmiş olduğunu gösterir (Gonzales and Woods, 2003).

RGB uzayından IHS uzayına dönüşüm için birçok yöntem tanımlanmıştır. Bu kadar çok yöntem olmasının nedeni tanımlanmış birçok IHS uzayı olmasıdır. Bütün IHS uzayları ile RGB uzayları arasında farklı ilişki vardır. Örneğin bazı IHS uzayları ton bileşeni için kırmızı eksenini referans alırken bazıları mavi eksenini referans alır. IHS uzayındaki bu tutarsızlıklar belirlenen yoğunluk bileşenini de etkilemektedir. Smith' s Triangle yaklaşımına göre yoğunluk bileşeni kırmızı, yeşil ve mavi değerlerin ortalamasıdır (Nunez et al., 1999).

$$I = \frac{K + Y + M}{3} \quad (5)$$

Diğer bir yaklaşıma göre de yoğunluk bileşeni kırmızı, yeşil ve mavi değerlerin toplamına eşittir (Harrison and Jupp, 1990).

$$I = K + Y + M \quad (6)$$

Bir başka yaklaşım ise yoğunluk bileşenini şu şekilde hesaplar;

$$I = \frac{1}{\sqrt{3}}K + \frac{1}{\sqrt{3}}Y + \frac{1}{\sqrt{3}}M \quad (7)$$

Smith's Hexcone isimli yaklaşım da kırmızı, yeşil ve mavi değerlerin hangisi daha yüksekse o değeri yoğunluk olarak kabul etmektedir (Nunez et al., 1999; Brown and Feringa, 2003).

$$I = \max(K, Y, M) \quad (8)$$

Bir yaklaşım da kırmızı, yeşil ve mavi değerlerden en yüksek olanı ile en düşük olanının ortalamasını yoğunluk olarak kabul eder (Nunez et al., 1999; Brown and Feringa, 2003).

$$I = \frac{\max(K, Y, M) + \min(K, Y, M)}{2} \quad (9)$$

Görüldüğü üzere yoğunluk değerinin hesaplanmasında herhangi bir standart geçerli değildir. Aynı durum ton ve renksel doygunluk değerleri için de geçerlidir.

RGB uzayından IHS uzayına dönüşüm bir ortogonal matris kullanılarak gerçekleştirilir. Bu metotta mavi eksen ton değerinin hesaplanmasında referans eksen olarak kabul edilmektedir (Nunez et al., 1999).

$$\begin{bmatrix} I \\ V_1 \\ V_2 \end{bmatrix} = \begin{bmatrix} \frac{1}{\sqrt{3}} & \frac{1}{\sqrt{3}} & \frac{1}{\sqrt{3}} \\ \frac{1}{\sqrt{6}} & \frac{1}{\sqrt{6}} & \frac{-2}{\sqrt{6}} \\ \frac{1}{\sqrt{2}} & \frac{-1}{\sqrt{2}} & 0 \end{bmatrix} \begin{bmatrix} K \\ Y \\ M \end{bmatrix} \quad (10)$$

V_1 ve V_2 değerleri hesaplandıktan sonra bu değerler kullanılarak H ve S hesaplanır.

$$H = \text{atan} \left(\frac{V_2}{V_1} \right) \quad (11)$$

$$S = \sqrt{V_1^2 + V_2^2}$$

IHS uzayından KYM (RGB) uzayına ters dönüşüm;

$$V_1 = S \cos(H) \quad (12)$$

$$V_2 = S \sin(H)$$

V_1 ve V_2 hesaplandıktan sonra kırmızı, yeşil ve mavi değerleri bulunur.

$$\begin{bmatrix} K \\ Y \\ M \end{bmatrix} = \begin{bmatrix} \frac{1}{\sqrt{3}} & \frac{1}{\sqrt{6}} & \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{3}} & \frac{1}{\sqrt{6}} & -\frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{3}} & -\frac{2}{\sqrt{6}} & 0 \end{bmatrix} \begin{bmatrix} I \\ V_1 \\ V_2 \end{bmatrix} \quad (13)$$

IHS ile görüntü kaynaştırma yöntemi en çok kullanılan görüntü kaynaştırma yöntemlerinden bir tanesidir. Bu yöntemde çok bantlı görüntü ilk olarak pankromatik görüntünün boyutlarına eşitlenir. Ardından RGB uzayından IHS uzayına yukarıda anlatıldığı gibi dönüştürülür. I bileşeni görüntünün konumsal detaylarını, H ve S bileşenleri ise görüntünün spektral detaylarını içerir. Elde edilen I bileşeni ile görüntü kaynaştırmada kullanılacak olan yüksek konumsal çözünürlüklü pankromatik görüntü yer değiştirilir. Pankromatik görüntü, H ve S bileşenlerine ters IHS dönüşümü uygulanır. Böylece RGB uzayına geri dönülerek kaynaştırılmış görüntü elde edilir.

Bu yöntemin en büyük dezavantajı sadece 3 tane multispektral bant kullanılarak I, H ve S bileşenlerinin hesaplanmasıdır (Chavez and Bowell, 1988). Eğer multispektral görüntünün üçten fazla sayıda bandı varsa bu yöntem kaynaştırma işlemini görüntünün bantlarının üçlü kombinasyonlarına göre yapar. Dolayısıyla her üçlü bant kombinasyonuna göre elde edilen sonuç farklı olmakla birlikte bu durumda elde edilen sonuç görüntüsü tutarsız olur (Güngör, 2008).

1.5.3.2. Temel Bileşenler Analizi (PCA) Dönüşümü ile Görüntü Kaynaştırma

Temel bileşenler analizi ile kaynaştırma yöntemi istatistiksel bir yöntem olup fotogrametri ve uzaktan algılamada görüntü iyileştirme ve sıkıştırma, değişim analizleri, sınıflandırma öncesinde sınıflandırmaya tabi olacak bant sayısının azaltılması, yapay sinir ağlarında özellik çıkarımı gibi işlemlerinde sıklıkla kullanılır (Akça ve Doğan, 2002).

Bu yöntemde konumsal çözünürlüğü düşük olan görüntünün boyutu kaynaştırmada kullanılacak görüntünün boyutuna eşitlenir ve temel bileşenler analizi uygulanır. Görüntüye n boyutlu lineer bir dönüşüm uygulanarak orijinal görüntü eigen vektör uzayına dönüştürülür (Shamshad et al., 2004). Yeni koordinat sisteminin eksenleri elde edilen temel bileşenler olur (Güngör, 2008). Oluşan bu yeni koordinat sisteminde bantlar arasındaki korelasyon ortadan kalkmış olur (Armenakis et al., 2003). En fazla eigen değere sahip olan vektör birinci ana bileşeni temsil eder ve bu ana bileşen görüntüdeki bütün bantların sahip olduğu konumsal veriyi tek başına barındırır (Petrou and Bosdogianni, 1999). Bu bileşenin görüntü kaynaştırmada kullanılacak olan pankromatik bant ile aynı olduğu kabulü yapılarak pankromatik bant ile bu bileşen yer değiştirilir. Daha sonra ters temel bileşenler dönüşümü uygulanarak kaynaştırılmış görüntü elde edilir. Elde edilen görüntü konumsal çözünürlük bakımından zenginleşmiş görüntüdür.

Uydu görüntülerinde matematiksel olarak her piksel bir piksel vektörü olarak temsil edilir. Bir piksele ait vektör aynı konumda bulunan tüm bantlardaki bütün gri değerlerden meydana gelir.

$$x_i = (x_1, x_2, \dots, x_k)^T \quad (14)$$

Burada x_i piksele ait vektörü, k toplam bant sayısını ve T transpoze işlemini göstermektedir.

Örneğin;

$$\begin{bmatrix} 5 & 3 & 4 \\ 1 & 7 & 6 \\ 2 & 8 & 9 \end{bmatrix} \text{ ve } \begin{bmatrix} 7 & 9 & 3 \\ 1 & 5 & 2 \\ 4 & 8 & 6 \end{bmatrix} \text{ gibi iki görüntü için } (1,2) \text{ konumundaki pikselin vektörü}$$

$$x_2 = \begin{bmatrix} 3 \\ 9 \end{bmatrix} \text{ ve } (2,3) \text{ konumundaki pikselin vektörü } x_6 = \begin{bmatrix} 6 \\ 2 \end{bmatrix} \text{ olur.}$$

Temel bileşenler dönüşümünde orijinal veri eigen vektör uzayına dönüştürüleceği için görüntünün kovaryans matrisi gereklidir. Kovaryans matrisin oluşturulabilmesi için görüntüdeki tüm piksellere ait ortalama vektörleri kullanılır (Gungor, 2008).

$$m = \frac{1}{M} \sum_{i=1}^M x_i \quad (15)$$

Buradaki M her bir banttaki toplam piksel sayısıdır. Ortalama vektör m kullanılarak kovaryans matris C_x elde edilir.

$$C_x = \frac{1}{M} \sum_{i=1}^M (x_i - m)(x_i - m)^T \quad (16)$$

Elde edilen C_x matrisi $k \times k$ boyutlarında olur. Eğer bantlar arasında yüksek korelasyon varsa C_x kovaryans matrisinde köşegen dışındaki terimlerin mutlak değerleri köşegendeki terimlerden daha büyük olacaktır (Akça ve Doğan, 2002).

C_x kovaryans matrisinin eigen vektörlerinden elde edilen A ortogonal matrisinin transpozisi A^T matrisi kullanılarak y_i piksel vektörleri elde edilir (Gungor, 2008).

$$y_i = A^T x_i \quad (17)$$

C_x matrisinin eigen değerleri büyükten küçüğe doğru sıralanır ve en büyük eigen değer eigen vektörü kullanılarak 1. temel bileşen elde edilir. Bu bileşen görüntüdeki konumsal detayın büyük çoğunluğunu içinde barındırır. Diğer temel bileşenler konumsal detay bakımından fakir, spektral detay bakımından zengindirler. Elde edilen 1. temel bileşen ile yüksek konumsal çözünürlüklü pankromatik görüntü yer değiştirilip ters temel bileşenler dönüşümü uygulanırsa pankromatik banttaki konumsal detaylar çok bantlı görüntüye aktarılmış olur.

1.5.3.3. Brovey, SVR ve CN Yöntemleri ile Görüntü Kaynaştırma

Brovey ve SVR (Synthetic Variable Ratio) yöntemlerinde konumsal çözünürlüğü düşük olan görüntünün bantlarının boyutları pankromatik görüntü ile eşitlenir. Daha sonra bu bantlar kullanılarak bir “intensity” bileşeni hesaplanır. Brovey yönteminde görüntünün bantları toplanarak “intensity” hesaplanırken SVR yönteminde bantların ağırlıklı ortalaması alınarak hesaplanır. Ağırlık katsayıları çok bantlı görüntü ile pankromatik görüntü arasında gerçekleştirilen regresyon analizi ile belirlenir. Her bir bant bulunan “intensity” bileşenine bölünür ve pankromatik görüntüyle çarpılır. Böylece konumsal çözünürlük bakımından zenginleştirilmiş yeni görüntü elde edilir. Brovey yöntemi görüntünün histogramındaki yüksek ve düşük kenardaki zıtlığı arttırmak için geliştirilen bir yöntemdir (Saroğlu vd., 2004).

$$T_i = \frac{B_i}{I} \times Pan \quad (18)$$

Burada T_i kaynaştırılmış görüntüyü, i bant sayısını, I intensity bileşenini ve Pan ise pankromatik görüntüyü temsil eder.

Brovey yöntemi piksellerin gri değerlerinde değişiklikler yaptığından dolayı renk bozulmalarına neden olabilir. Daha sağlıklı sonuç alınabilmesi için kaynaştırılacak görüntülerin aynı sensörden çekilmiş veya yakın tarihli görüntüler olması gereklidir. Kaynaştırma işleminden sonra elde edilen görüntüye uygulanacak olan yeniden örnekleme işlemi de önem arz etmektedir. Kaynaştırılacak olan görüntülerin konumsal çözünürlükleri arasındaki ilişki hangi yeniden örnekleme metodunun kullanılmasının daha faydalı olacağı hakkında bilgi verir. Görüntülerin konumsal çözünürlüklerinin oranı N belirlenir ve bu değer karesi alınarak kaç piksel komşuluğunda yeniden örnekleme yapılacağı hakkında bilgi elde edilir (Erdas Imagine Online Documents). Örneğin; ~ 28.5 m konumsal çözünürlüklü Landsat TM görüntüsü ile 10 m konumsal çözünürlüklü SPOT pankromatik görüntü kaynaştırılırken $N = 2.85$ bulunur ($28.5 \div 10 = 2.85$). $N^2 = 8.1$ olarak hesaplanır. Bikübik yeniden örnekleme metodu bir pikselin çevresindeki 16 pikseli kullanarak yeniden örnekleme işlemini gerçekleştirdiği için bu metodun kullanılması faydalı olur.

CN (Color Normalized) yöntemi ise Brovey görüntü kaynaştırma yönteminin geliştirilmiş halidir. Bu yöntemde de çok bantlı görüntünün her bir bandı pankromatik görüntüyle çarpılır ve çok bantlı görüntünün bantlarının toplamına bölünür. Bu yöntemin Brovey ile görüntü kaynaştırma yönteminden farkı formüle eklenen sabit sayılardır.

$$F_{k(i,j)} = \frac{(M_{k(i,j)} + 1.0)(P_{(i,j)} + 1.0) \times 3.0}{\sum_k M_{k(i,j)} + 3.0} \quad (19)$$

Bu formüldeki $M_{k(i,j)}$ çok bantlı görüntüyü, $P_{(i,j)}$ pankromatik görüntüyü ve $F_{k(i,j)}$ ise kaynaştırılmış görüntüyü göstermektedir.

1.5.3.4. Ehlers Görüntü Kaynaştırma Yöntemi

Bu yöntemde Fourier ve IHS dönüşümü bir arada kullanılır. İlk işlem olarak çok bantlı görüntünün boyutları kaynaştırmada kullanılacak olan pankromatik görüntüye eşitlenerek IHS dönüşümü uygulanır. Sonra pankromatik görüntüye 2 boyutlu FFT (Fast Fourier Transformation) dönüşümü uygulanarak frekans ortamına geçilir ve yüksek geçirgen filtreleme yapılır. Daha sonra ters Fourier dönüşümü uygulanarak yersel koordinatlara geçiş sağlanır. Bu sayede pankromatik görüntüdeki konumsal detaylar güçlendirilmiş olur. Çok bantlı görüntüye IHS dönüşümü uygulanır ve yoğunluk (I) bileşeni yine 2 boyutlu FFT kullanılarak frekans ortamına geçirilir. Frekans ortamındaki yansıma şiddeti üzerinde alçak geçirgen filtreleme işlemi gerçekleştirildikten sonra yersel koordinatlara geri geçiş yapılır. Alçak ve yüksek filtre sonuçları toplanır ve ortaya çıkan görüntü yeni I bileşeni olur. I yeni bileşeni ile orijinal H ve S bileşenlerine ters IHS dönüşümü uygulanarak kaynaştırılmış görüntü elde edilir. Elde edilen görüntü konumsal anlamda zenginleştirilmiş olup, aynı zamanda çok bantlı görüntünün spektral özellikleri korunmuş olur. Bu yöntemdeki filtreler pankromatik görüntüden kaynaklanan renk bozulma etkilerini en aza indirecek şekilde tasarlanmalıdır (Ehlers, 2005). Erdas Imagine yazılımı kentsel ve kırsal alanlar için ayrı ayrı filtre seçenekleri sunmaktadır.

1.5.3.5. Multiplicative Görüntü Kaynaştırma Yöntemi

Basit işlemlere dayalı fazla zaman almayan bir görüntü kaynaştırma yöntemidir. Bu yöntemde çok bantlı görüntünün boyutları pankromatik görüntüye eşitlenir ve yeniden örneklenmiş çok bantlı görüntüdeki her bir pikselin gri değeri pankromatik görüntüde kendi konumuna karşılık gelen pikselin gri değeriyle çarpılarak kaynaştırılmış görüntü elde edilir (Pohl, 1997).

$$F = MS \times Pan \quad (20)$$

1.5.3.6. HPF (High Pass Filter) Görüntü Kaynaştırma Yöntemi

HPF yöntemi ilk defa Landsat görüntülerinin konumsal çözünürlüklerini arttırmak amacıyla tanıtılmıştır. Bu yöntemde göre ilk olarak pankromatik görüntünün konumsal çözünürlüğü ile çok bantlı görüntünün konumsal çözünürlüğünün oranı R hesaplanır. Hesaplanan R değerine göre pankromatik görüntüye uygulanacak yüksek geçiren filtrenin boyutları belirlenir. Ardından bu filtre kullanılarak pankromatik görüntü filtrelenir ve böylece pankromatik görüntüdeki konumsal detaylar güçlendirilmiş olur. Çok bantlı görüntünün boyutları pankromatik görüntünün boyutlarına eşitlenir. Filtrelenmiş görüntü çok bantlı görüntünün tüm bantlarına eklenir. Ekleme işleminden önce çok bantlı görüntü için R oranı kullanılarak ağırlıklar (W) belirlenir. Son olarak elde edilen kaynaştırılmış görüntüye lineer bir germe işlemi uygulanarak standart sapma ve ortalama değerlerinin orijinal çok bantlı görüntüyle eşlenmesi sağlanır (Gangkofner and Holcomb, 2008). Bu yöntem farklı sensörlerden alınan uydu görüntülerinin ve farklı tarihlerde çekilen uydu görüntülerinin kaynaştırılmasında başarı göstermektedir (Klonus and Ehlers, 2009).

1.5.3.7. Gram-Schmidt Dönüşümü ile Görüntü Kaynaştırma

Temel Bileşenler Analizi yöntemi gibi bu yöntem de görüntü transformasyonuna dayanır. Bu yöntemde düşük konumsal çözünürlüklü çok bantlı görüntünün boyutları pankromatik görüntünün boyutlarına eşitlenir. Daha sonra çok bantlı görüntünün bantları kullanılarak bunlardan düşük çözünürlüklü pankromatik görüntü ($DÇP$) elde edilir. Bu

pankromatik görüntü çok bantlı görüntünün ilk bandı olarak kullanılır ve bu görüntüyle birlikte çok bantlı görüntünün diğer bantlarına Gram-Schmidt dönüşümü uygulanır. Daha sonra yüksek konumsal çözünürlüklü pankromatik görüntü ile dönüşüm sonucu elde edilen görüntünün ilk bandı yer değiştirilir. Son olarak elde edilen görüntüye ters Gram-Schmidt uygulanarak kaynaştırılmış görüntü elde edilir (Laben and Brower, 2000). Bu yöntem aynı sensörden alınan görüntülerin kaynaştırılmasında oldukça başarılıdır.

Çok bantlı görüntüden pankromatik görüntü elde etmek için 2 yöntem vardır (Laben and Brower, 2000). İlk yöntemde ağırlıklar kullanılarak pankromatik görüntü elde edilir. Mavi, yeşil, kırmızı ve kızılötesi bantlardan oluşan bir görüntü için ağırlıklar;

$$\begin{aligned}
 M_a &= \int_{0.4}^{0.5} OG_M(\lambda) \times SR_M(\lambda) \times SR_{Pan}(\lambda) d\lambda \\
 Y_a &= \int_{0.5}^{0.6} OG_Y(\lambda) \times SR_Y(\lambda) \times SR_{Pan}(\lambda) d\lambda \\
 K_a &= \int_{0.6}^{0.7} OG_K(\lambda) \times SR_K(\lambda) \times SR_{Pan}(\lambda) d\lambda \\
 KÖ_a &= \int_{0.7}^{0.9} OG_{KÖ}(\lambda) \times SR_{KÖ}(\lambda) \times SR_{Pan}(\lambda) d\lambda
 \end{aligned} \tag{21}$$

şeklinde elde edilir. Burada M_a , Y_a , K_a ve $KÖ_a$ sırasıyla mavi, yeşil, kırmızı ve kızılötesi bantların ağırlıklarını; OG optik geçirgenliği, SR spektral yansımayı ve λ ise dalga boyunu göstermektedir. Bu ağırlıklar kullanılarak pankromatik görüntü elde edilir.

$$DÇP = (M \times M_a) + (Y \times Y_a) + (K \times K_a) + (KÖ \times KÖ_a) \tag{22}$$

İkinci yöntemde ise $DÇP$ yüksek konumsal çözünürlüklü pankromatik görüntüden elde edilir.

$$GS_1(i, j) = DÇP(i, j) \tag{23}$$

GS_1 Gram-Schmidt dönüşümünden sonra elde edilen görüntünün ilk bandıdır. Gram-Schmidt metodu bir matrisi veya görüntüyü ortogonalleştirerek çok bantlı görüntünün bantlarındaki fazlalık olan verileri kaldırır. Gram-Schmidt yönteminde ortogonalleştirme işleminden önce her bir bandın ortalaması ilgili banttaki her bir pikselden çıkartılır. Her bir Gram-Schmidt bandı (T) kendisinden önceki bant ($T-1$) kullanılarak elde edilir.

$$GS_T(i, j) = (B_T(i, j) - \mu_T) - \sum_{l=1}^{T-1} \phi(B_T, GS_l \times GS_l(i, j)) \quad (24)$$

Burada T dönüşüm gerçekleştirilecek bandı, B orijinal bandı ve μ_T ise T bandının ortalamasını göstermektedir. μ_T ortalaması ise;

$$\mu_T = \frac{\sum_{j=1}^C \sum_{i=1}^R B_T(i, j)}{C \times R} \quad (25)$$

şeklinde hesaplanır. Bu denklemdeki C toplam sütun sayısını ve R toplam satır sayısını göstermektedir. $\phi(B_T, GS_l)$ hesaplanması ise şu şekildedir;

$$\phi(B_T, GS_l) = \left[\frac{\sigma(B_T, GS_l)}{\sigma(B_T, GS_l)^2} \right] \quad (26)$$

İlk Gram-Schmidt bandının ve yüksek konumsal çözünürlüklü görüntünün ortalaması μ ve standart sapması σ hesaplanır.

$$\sigma_T = \sqrt{\frac{\sum_{j=1}^C \sum_{i=1}^R (B_T(i, j) - \mu_T)^2}{C \times R}} \quad (27)$$

Yüksek konumsal çözünürlüklü görüntüye kontrast germe işlemi uygulanarak ortalaması ve standart sapması ilk Gram-Schmidt bandının ortalaması ve standart sapmasına eşlenir. Bu sayede orijinal çok bantlı görüntüdeki spektral yapı korunmuş olur.

Kontrast germe işlemi uygulanan görüntü ilk Gram-Schmidt bandı ile yer değiştirilir ve ters Gram-Schmidt dönüşümü uygulanarak kaynaştırılmış görüntü elde edilir. Ters Gram-Schmidt dönüşümü;

$$B_T(i, j) = (GS_T(i, j) + \mu_T) - \sum_{l=1}^{T-1} \Phi(B_T, GS_l) \times GS_l(i, j) \quad (28)$$

şeklindedir.

1.5.3.8. Kriter Tabanlı Görüntü Kaynaştırma Yöntemi

Bu yöntem Güngör ve Shan (2005) tarafından geliştirilmiştir. Görüntü kaynaştırma işleminde konumsal çözünürlüğü arttırmanın yanında spektral yapıyı korumada oldukça başarılı bir yöntemdir. Bu yöntemde göre kaynaştırılmış bantlar pankromatik görüntünün ve çok bantlı görüntünün bantlarının lineer kombinasyonu şeklinde hesaplanır (Güngör, 2008).

$$F_{k(m,n)} = a_{(m,n)} \cdot I_{0(m,n)} + b_{(m,n)} \cdot I_{k(m,n)} \quad (29)$$

Burada m ve n satır ve sütun numaralarını, $k = 1, 2, \dots, N$ ($N =$ toplam bant sayısı), F_k kaynaştırılmış bant, I_0 pankromatik görüntü, I_k boyutu pankromatik görüntünün boyutuna çıkarılmış çok bantlı görüntünün k ' inci bandı, a ve b ise her bir piksel konumu için hesaplanması gereken ağırlık katsayılarıdır. Bu katsayılar bilinmeyenlerdir ve pankromatik görüntü ile çok bantlı görüntünün kaynaştırılmış görüntüye olan katkılarını göstermektedir. Bu katsayıları hesaplamak için 3 kriter tanımlanmıştır (Güngör, 2008).

Kriter 1: Kaynaştırılmış görüntünün varyansı pankromatik görüntünün varyansına eşit olmalıdır. Böylece pankromatik görüntüdeki konumsal detaylar kaynaştırılmış görüntüye aktarılabilir.

$$Cov(F_k, F_k) = a_k^2 \sigma_0^2 + 2a_k b_k \sigma_{0k} + b_k^2 \sigma_k^2 = \sigma_0^2 \quad (30)$$

Burada σ_0^2 ve σ_k^2 sırasıyla pankromatik ve çok bantlı görüntülerin varyanslarını, σ_{0k} pankromatik görüntü ile çok bantlı görüntünün k ' inci bandı arasındaki kovaryansı göstermektedir.

Kriter 2: Her bir kaynaştırılmış bandın ortalaması her bir çok bantlı görüntünün bandının ortalamasına eşit olmalıdır. Böylece çok bantlı görüntünün renk yapısı kaynaştırılmış görüntüde bozulmadan kalacaktır.

$$\text{Mean}(F_k) = a_k \mu_0 + b_k \mu_k = \mu_k \quad (31)$$

Burada μ_0 ve μ_k sırasıyla pankromatik görüntü ve çok bantlı görüntünün k ' inci bandının ortalamalarını göstermektedir.

Kriter 3: Bu kriter çok bantlı görüntünün bantları arasındaki oranın kaynaştırılmış görüntünün bantları arasında da değişmemesi için kullanılmaktadır.

$$F_{k(m,n)} = C_{(m,n)} \cdot I_{k(m,n)} \quad (32)$$

Bu formüldeki $C_{(m,n)}$ her bir piksel konumunda her bir bant için sabittir ve çok bantlı görüntünün bantları arasındaki oranın kaynaştırma sonrası korunmasını sağlar. Bu kriterlere göre her bir piksel konumu için bu formüller yazıldığında kaynaştırılmış piksel değerleri hesaplanır (Güngör, 2008).

$$\begin{aligned} F_{k(m,n)} &= a_{(m,n)} \cdot I_{0(m,n)} + b_{(m,n)} \cdot I_{k(m,n)} \\ a_{k(m,n)}^2 \sigma_0^2 + 2a_{k(m,n)} b_{k(m,n)} \sigma_{0k} + b_{k(m,n)}^2 \sigma_k^2 &= \sigma_0^2 \end{aligned} \quad (33)$$

$$a_{k(m,n)} \mu_0 + b_{k(m,n)} \mu_k = \mu_k$$

$$F_{k(m,n)} = C_{(m,n)} \cdot I_{k(m,n)}$$

Bu formüller toplam $4 * k$ ve $r = k - 1$ fazlalıkla en küçük kareler yöntemi kullanılarak çözülür. Bu yöntemde başlangıç değerleri olarak $C_{(m,n)}$ için 1, a ve b değerleri için 0,5 alınması önerilir.

Bu formüllerin uygulanması için pankromatik ve çok bantlı görüntülerde küçük pencereler gezdirilir. Bu görüntülerin konumsal çözünürlüklerinin oranından büyük olan en yakın tamsayı gezdirilecek olan pencerenin boyutunu belirler. Hesaplanan varyans, kovaryans ve ortalama verileri sadece alınan pencerenin içindeki pikseller kullanılarak hesaplanır (Güngör, 2008).

1.5.3.9. Dalgacık Dönüşümü ile Görüntü Kaynaştırma

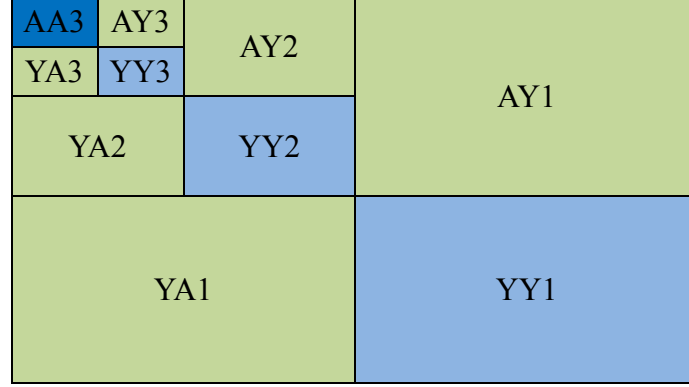
Dalgacık dönüşümü (Wavelet) teorisi Fourier dönüşümü teorisine benzerdir. Fourier dönüşümünde uzun ve sürekli sinüs ile kosinüs dalgaları kullanılırken Dalgacık dönüşümü uzun dalgalar yerine kısa ve ayrık “Wavelet” ’ ler kullanır. Dalgacık teorisinin temeli görüntünün yüksek ve alçak frekans bileşenlerine ayrılmasına dayanır (Erdas Imagine Online Documents). Örneğin; orijinal görüntüye alçak geçirgen bir filtre kullanılarak alçak frekans görüntüsü elde edilir. Alçak frekans görüntüsü orijinal görüntüden çıkarıldığında yüksek frekans görüntüsüne ulaşılır. Bu elde edilen yüksek frekans görüntüsü, orijinal görüntüye yüksek geçirgen filtre uygulanması durumunda elde edilecek olan yüksek frekans görüntüsüyle birebir aynıdır. Alçak frekans görüntüsüyle yüksek frekans görüntüsü orijinal görüntüdeki bütün bilgileri barındırır.

Görüntü füzyonunda yüksek konumsal çözünürlüklü pankromatik görüntünün konumsal detaylarının çok bantlı görüntüye aktarılması temel amaç olduğundan pankromatik görüntülerden elde edilen yüksek frekans görüntülerinin önemi oldukça fazladır.

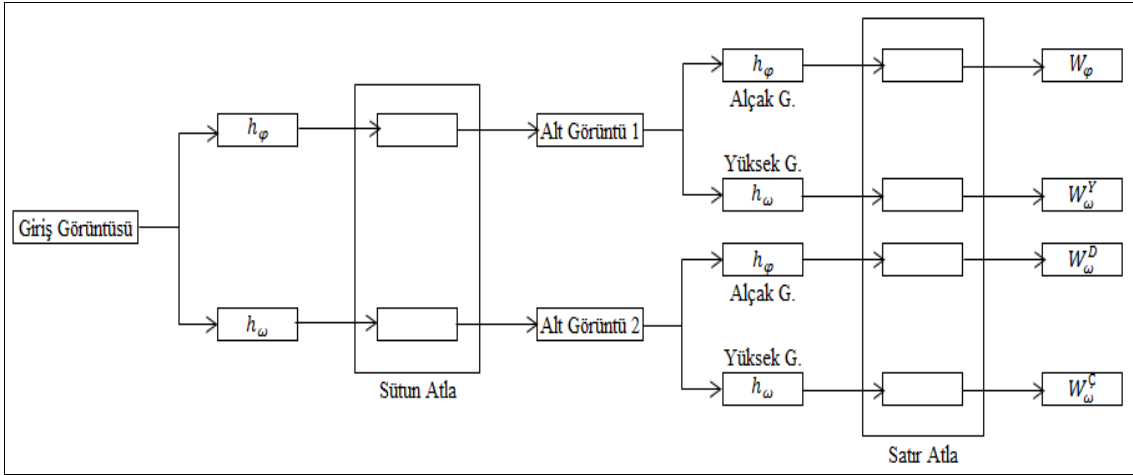
1.5.3.9.1. 2 Boyutlu Dalgacık Dönüşümü

Uydu görüntüleri 2 boyutlu oldukları için 2 boyutlu Dalgacık dönüşümü kullanılır. Bu dönüşüm yöntemine göre orijinal görüntüye yüksek (h) ve alçak (g) geçirgen dalgacık filtre uygulanır. Her filtrelemeden sonra satır ve sütunlardaki katsayılar birer satır ve sütun atlayarak silinir (decimation). İlk seviyedeki ayrıştırma işlemi sonucunda görüntü AA (Alçak-Alçak), AY (Alçak-Yüksek), YA (Yüksek-Alçak) ve YÜY (Yüksek-Yüksek) olmak üzere 4 yeni görüntü elde edilir. Elde edilen bu 4 görüntüden bir tanesi (AA) düşük frekans

bilgisini, diğerleri ise yatay, dikey ve çapraz detay bilgisini içerir. Bundan sonraki seviyelerde ayrıştırma işlemi sadece AA bandı üzerinde gerçekleştirilir (Güngör, 2008).



Şekil 6. 3 seviye için WD görüntü piramidi




Şekil 7. 2 Boyutlu ayrık dalgacık dönüşümü akışı (Erdas Imagine Online Documents).

Şekil 7' de 2 boyutlu ayrık dalgacık dönüşümünün akış şeması görülmektedir. Bu şekildeki h_φ ve h_ω sırasıyla yüksek geçirgen ve alçak geçirgen dalgacık filtrelerini, W_φ , W_ω^Y , W_ω^D ve W_ω^C ise sırasıyla düşük frekans, yatay, dikey ve çapraz (diagonal) bilgileri göstermektedir.

Dalgacık dönüşümünün çalışma mantığı pankromatik görüntünün filtrelenmesine dayanır. Örneğin; 5 m konumsal çözünürlüklü pankromatik bir görüntü ile 40 m konumsal çözünürlüklü çok bantlı bir görüntünün kaynaştırılması işleminde ilk aşamada pankromatik görüntüye alçak ve yüksek geçirgen dalgacık filtresi uygulanırsa yüksek frekans görüntüsü

ve 10 m konumsal çözünürlüklü yeni alçak frekans görüntüsü elde edilir. Bir sonraki seviyede 20 m konumsal çözünürlüklü yeni görüntü ve yüksek frekans görüntüsü, son seviyede ise 40 m konumsal çözünürlüklü düşük frekans görüntüsü ve son yüksek frekans görüntüsü elde edilir. Her iki görüntüden elde edilen düşük frekans dönüşüm katsayıları ile detay katsayıları kullanılarak bir kaynaştırma kuralına göre kaynaştırılır. Son olarak hazırdaki bulunan yüksek frekans görüntüleriyle birlikte dalgacık dönüşümü tersten uygulanırsa 5 m konumsal çözünürlüklü kaynaştırılmış görüntü elde edilir.



Şekil 8. Orijinal görüntü (solda) ve orijinal görüntüye ait 2 seviyeli AA, YA, AY ve YÜY alt görüntüleri (sağda) (Canga, 2002).

Dalgacık dönüşümünün tersine literatürde “reconstruction” denilmektedir. Ters dönüşümün her seviyesinde dalgacık katsayıları yukarıya ara değer olarak kestirilir (interpolation). Bu kestirim görüntünün her katsayısının arasına sıfırlar yerleştirmekle olur.

Bu aşamadan sonra her görüntü “reconstruction” filtresiyle filtrelenir. Bu filtre orijinal dalgacık filtresinin birebir tersidir. Filtrelemeden sonra her dört görüntü birbirine eklenir ve bir yüksek seviyedeki AA (Alçak-Alçak) görüntü elde edilir. Bu işlem ulaşılmak istenilen seviyeye gelinceye kadar devam eder (Çölova, 2010).

1.5.3.10. Yeni Bir Yöntem

Bu yöntem görüntünün spektral yapısını bozmadan görüntü kaynaştırma işlemini gerçekleştirmek amacıyla Yıldırım ve Güngör (2012) tarafından geliştirilmiştir (Yıldırım ve Güngör, 2012). Bu yöntemde t isimli sabit görüntüleri içeren bir uzay oluşturulur ve bu uzaydaki görüntülerin boyutları pankromatik görüntü ile aynı olmaktadır. t uzayındaki ve pankromatik görüntüdeki fazlalık bilgiler çıkartılarak kaynaştırma için gerekli olan bilgiler

ortaya çıkartılır. P pankromatik görüntü olmak üzere P görüntüsünün t uzayındaki bölümü ayrılır ve konumsal detayları içerisinde barındıran P_0 elde edilir. Pankromatik görüntü ile P_0 görüntüsünün farkı t' ye eşit olur. Bunun yanında t' nin kovaryans ve ortalama değerleri 0' a eşit olur. Z çok bantlı görüntüler içerisinde konumsal bilgi kaybı olmadan yeniden örneklenerek boyutu pankromatik görüntü ile aynı yapılmış orijinal çok bantlı görüntüye en yakın görüntüdür. Sonuç görüntüsünde her bir bant için her bir pikselin değeri bütün bantlardaki ilgili piksellerin değerlerine bağlıdır. Bu bağlantı, f_r isimli yerel standart sapmaya bağlı fonksiyonlar serisi ve pozitif bir r parametresi yardımıyla tanımlanır. Bu r parametresi renk ve konumsal bilgi aktarımında dengeyi sağlamaktadır (Yıldırım ve Güngör, 2012). $f_r(r > 0)$ ' lar için şunlar geçerlidir:

- $[0,1]$ aralığında sürekli, $f_r(0) = 0, f_r(1) = 1$.
- $(0,1)$ aralığında sürekli ve bir türeve sahip, ayrıca bu türev pozitif.
- $r \geq 1$ için dışbükey ve $0 < r \leq 1$ için içbükey.
- $r, (0,1)$ aralığındaki s' ye yakınsarken, $f_r f_s'$ ye $L^\infty([0,1])$ ' de yakınsar.
- R sıfıra giderken $f_r g_1'$ e $L^\infty([0,1])$ ' de yakınsar.
- Her $\varepsilon > 0$ için öyle bir r_ε değeri vardır ki, her $r > R_\varepsilon$ için $\|f_r - g_2\|_\infty < \varepsilon$
 $g_1(x) = 1, x(0,1]$ içindeyse $g_1(0) = 0$
 $g_2(x) = 0, x[0,1)$ içindeyse $g_2(1) = 1$

1.5.4. Kaynaştırılmış Görüntülerin Kalitelerinin Değerlendirilmesi

Literatürde görüntü kaynaştırma yöntemlerinin başarısını ölçebilmek amacıyla çeşitli metrikler kullanılmaktadır. Bu çalışma kapsamında RMSE, ERGAS, SAM, RASE ve SID metrikleri kullanıldığından dolayı sadece bu metrikler hakkında bilgi verilecektir.

1.5.4.1. RMSE

Veri setleri arasındaki karesel ortalama hatadır. Her bir pikseldeki değişim miktarını hesaplar. Çok bantlı görüntünün k' inci bandı ile kaynaştırılmış görüntünün k' inci bandı arasındaki karesel ortalama hata (B_k);

$$Spektral RMSE(B_k) = \sqrt{\frac{1}{M * N} \sum_{i=1}^M \sum_{j=1}^N (R_k(i,j) - F_k(i,j))^2} \quad (34)$$

şeklinde olmaktadır (Dammavalam et al., 2012). Burada R_k boyutu kaynaştırmada kullanılan pankromatik görüntüye eşitlenmiş orijinal çok bantlı görüntünün k ' inci bandını, F_k kaynaştırılmış görüntünün k ' inci bandını, M ve N ise sırasıyla görüntünün satır ve sütun sayılarını göstermektedir. Kaynaştırılmış görüntünün konumsal detay yapısını görüntü kaynaştırmada kullanılan pankromatik görüntü yardımıyla kontrol etmek amacıyla Konumsal RMSE tanımlanmıştır (Lillo-Saavedra et al., 2005).

$$Konumsal RMSE = \sqrt{\frac{1}{M * N} \sum_{i=1}^M \sum_{j=1}^N (Pan_k(i,j) - F_k(i,j))^2} \quad (35)$$

Bu formülün spektral RMSE' den farkı orijinal çok bantlı görüntünün yerine pankromatik görüntü (Pan_k) kullanılmasıdır. Pan_k bu formülde kullanılmadan önce pankromatik görüntünün histogramı kaynaştırılmış görüntülerin bantlarının histogramlarına eşlenmelidir (Gonzalo-Martin and Lillo-Saavedra, 2011).

1.5.4.2. RASE

RASE hata indeksi kaynaştırılmış görüntülerin spektral kalitesini ölçme amacıyla tanımlanmıştır. Bu yöntem karesel ortalama hatadan (Spektral RMSE) ve ortalama parlaklıktan (M) faydalanmaktadır. RASE hata indeksi yüzde cinsindedir;

$$RASE = \frac{100}{M} \sqrt{\frac{1}{K} \sum_{k=1}^K Spektral RMSE(B_k)^2} \quad (36)$$

şeklinde tanımlanmaktadır (Wald, 2002). Ortalama parlaklık (M) ise şu şekilde hesaplanmaktadır (Saroğlu vd., 2004);

$$M = \frac{1}{K} \sum_{k=1}^K M_k \quad (37)$$

Bu formüllerdeki K toplam bant sayısını, M_k ise orijinal çok bantlı görüntünün k 'inci bandının ortalamasını göstermektedir. RASE değeri ne kadar küçük olursa her iki görüntü birbirine spektral olarak o kadar fazla benziyor demektir. RASE yönteminin dezavantajı her iki görüntü arasındaki çözünürlük farkını dikkate almamasıdır (Gungor, 2008). Bu sorunu çözmek amacıyla ERGAS metriği tanımlanmıştır.

1.5.4.3. ERGAS

Bu metrik karesel ortalama hatadan ve kaynaştırılacak olan görüntülerin konumsal çözünürlüklerinden faydalanır (Alparone et al., 2004).

$$Spektral\ ERGAS = 100 \frac{h}{l} \sqrt{\frac{1}{K} \sum_{k=1}^K \left(\frac{Spektral\ RMSE(k)}{\mu(k)} \right)^2} \quad (38)$$

Bu formüldeki h ve l sırasıyla pankromatik görüntü ve çok bantlı görüntünün konumsal çözünürlüklerini, $\mu(k)$ k bandının ortalamasını, K toplam bant sayısını, $RMSE(k)$ ise çok bantlı görüntünün k 'inci bandı ile kaynaştırılmış görüntünün k 'inci bandı arasındaki karesel ortalama hatasını göstermektedir (Gungor, 2008). ERGAS metriğinin SAM metriğine üstünlüğü ERGAS metriğinin SAM metriğinin aksine orijinal görüntü ve kaynaştırılmış görüntülerin ortalamalarındaki farklılıkları dikkate almasıdır. Aynı zamanda ERGAS metriği muhtemel radyometrik distorsiyonları belirler. ERGAS yönteminin dezavantajı ise kaynaştırılmış görüntü ve orijinal çok bantlı görüntü arasındaki korelasyonları dikkate almamasıdır (Gungor, 2008). Literatürde kaynaştırılmış görüntünün konumsal detaylarını test etmek amacıyla Konumsal ERGAS tanımlanmıştır (Lillo-

Saavedra et al., 2005). Spektral ERGAS formülünde *Spektral RMSE* yerine *Konumsal RMSE* ve μ yerine *Pan* yazılırsa Konumsal ERGAS;

$$Konumsal\ ERGAS = 100 \frac{h}{l} \sqrt{\frac{1}{K} \sum_{k=1}^K \left(\frac{Konumsal\ RMSE(k)}{Pan(k)} \right)^2} \quad (39)$$

şeklinde hesaplanır.

1.5.4.4. SAM

Bir görüntüdeki her bir piksel konumunun bütün bantlardaki gri değerleri o piksel konumu için spektral vektörü oluşturur. Uydu görüntüleri bu şekilde spektral vektörlerden meydana gelir. SAM iki spektral vektör arasındaki açının mutlak değerini hesaplayan bir metriktir (Strait et al., 2008). Her iki spektral vektör arasındaki açı sıfır ise bu görüntüler arasında spektral distorsiyon yoktur.

$$\cos \alpha = \frac{\sum_{i=1}^N A_i B_i}{\sqrt{\sum_{i=1}^N A_i A_i} \sqrt{\sum_{i=1}^N B_i B_i}} \quad (40)$$

Bu formüldeki N toplam bant sayısını, $A = (A_1, A_2, A_3, \dots, A_N)$ ve $B = (A_1, A_2, A_3, \dots, A_N)$ sırasıyla çok bantlı görüntü ve kaynaştırılmış görüntüde iki spektral vektörü göstermektedir. α ise belli bir noktadaki spektral açığı ifade etmektedir. Bütün görüntü için SAM değerini hesaplamak için bütün α değerlerinin ortalaması alınır (Strait et al., 2008). Kaynaştırılmış görüntü ve orijinal çok bantlı görüntüdeki iki spektral vektör birbirlerine paralel olabilir ancak eğer bu vektörlerin büyüklükleri farklı ise radyometrik distorsiyon meydana gelir. SAM yönteminin dezavantajı kaynaştırılmış görüntülerdeki radyometrik distorsiyonu tespit edememesidir (Saroğlu vd., 2004).

1.5.4.5. SID

SAM metodunun geliştirilmiş halidir. Bu yöntem piksel değerlerinin dağılımını rastgele birer değişken olarak değerlendirip olasılık bilimi açısından benzerliğini ölçmektedir (Strait et al., 2008). SID;

$$SID(x, y) = D(x||y) + D(y||x) \quad (41)$$

formülüyle bulunmaktadır (Strait et al., 2008). Bu formüldeki $x = (x_1, \dots, x_N)^T$ ve $y = (x_1, \dots, x_N)^T$ sırasıyla orijinal çok bantlı görüntü ve kaynaştırılmış görüntüdeki birer vektördür. Ancak vektörleri oluşturan x_i ve y_i değerleri 0-1 aralığında olmalıdır. Bu yüzden;

$$p_j = \frac{x_j}{\sum_{i=1}^N x_i} \quad (42)$$

$$q_j = \frac{y_j}{\sum_{i=1}^N y_i}$$

değişkenleri tanımlanır. Ana formüldeki $D(x||y)$ ve $D(y||x)$ sırasıyla;


$$D(x||y) = \sum_{i=1}^L p_i \log\left(\frac{p_i}{q_i}\right) \quad (43)$$

$$D(y||x) = \sum_{i=1}^L q_i \log\left(\frac{q_i}{p_i}\right)$$

şeklinde hesaplanır (Strait et al., 2008).

1.6. Görüntü Sınıflandırma

Sınıflandırma aynı spektral yapıya sahip olan nesnelerin gruplandırılmasıdır. Bir başka deyişle görüntüdeki her bir pikselin arazide hangi özellik sınıfına dahil olduğunun belirlenmesidir. Sınıflandırma işleminde görüntüye ait piksellerin gri değerleri ile yapılan istatistiksel hesaplamalar esas alınır. Bu gri değerler kullanılarak bazı sınıflandırma yöntemleri aracılığıyla piksellerin sınıfları belirlenir.



Şekil 9. Sınıflandırma işleminin şematik gösterimi (Çelik, 2006).

Sınıflandırma işleminde, başlangıçta var olan veri ve bilgilerin tür ve miktarına göre problem yaklaşım ve çözüm yolları farklı olmaktadır. Sınıflandırmada kullanılacak bant kombinasyonlarını belirlemek amacıyla çalışma alanına ait çok spektrumlu veri dizisindeki korelasyon irdelenmelidir. Bunun için korelasyon matrisi oluşturulmalı ve korelasyon katsayıları incelenerek minimum korelasyona sahip bantlar sınıflandırmada kullanılmalıdır (Ayhan vd., 2003).

Sınıflandırma işlemleri genel olarak şu adımlardan oluşur (Kansu, 2006);

1. Sınıflandırma projesi tasarlanır. Sınıflandırmada kullanılacak olan sınıfların kaç tane ve hangileri oldukları belirlenir. Bu sınıflar orman alanları, yol, su veya kent alanları olabilir. Bu aşamada sınıflandırma işlemi gerçekleştirilecek alan için arazi çalışması yapılarak bu bölgeye ait veriler toplanır.

2. Arazideki her bir sınıfı temsil etmek üzere imzalar (signature) toplanır veya yazılımlarda kümeleme yapılır. İmza toplanıyorsa seçilen imzalar tanımlanmak istenilen sınıfla uyum içinde olmalıdır. Gereğinden fazla imza kullanılmamalıdır.

3. Uygun bir algoritma seçilerek sınıflandırma işlemi gerçekleştirilir.

4. Eğer ihtiyaç varsa görüntüye geometrik düzeltme yapılır ve görüntüye koordinat kazandırılır.

5. Sınıflandırma işleminin doğruluk analizleri (accuracy assessment) gerçekleştirilir ve sınıflandırma sonuçları araziyle karşılaştırılarak sınıflandırma doğruluğu irdelenir.

1.6.1. Kontrollü Sınıflandırma (Supervised Classification)

Bu sınıflandırma yönteminde arazideki sınıflar sınıflandırmayı gerçekleştiren kişi tarafından bilgisayara tanıtılır veya daha önce o bölgeye ait belirlenmiş spektral bilgiler varsa bunlar kullanılarak her bir pikselin ait olduğu sınıf belirlenir. Kontrollü sınıflandırma işleminde ilk yapılması iş arazideki sınıfların kaç tane olduğu ve bu sınıfların neler olduklarının belirlenmesidir. Daha sonra arazideki sınıfların görüntü işleme yazılımına tanıtılması amacıyla görüntü üzerinden imzalar (signature) toplanır ve sınıflandırma işlemi için gerekli olan istatistiksel temel (ortalama, standart sapma, kovaryans matrisi vb.) oluşturulur. Oluşturulan bu istatistiksel özelliklerden faydalanılarak görüntüdeki bütün piksellerin sınıfları belirlenir. İmzaların toplanması işleminde dikkat edilmesi gereken bazı noktalar vardır. Toplanan imzalar sınıfları kesin olarak bilinen yerlerden toplanmalıdır. Bunun için arazi çalışması için o bölgeye gidilir ve arazide hangi nesnelerin hangi alanlarda bulduklarına dair bilgiler toplanır veya o bölgeye ait harita, plan gibi altlıklardan faydalanılabilir. Toplanan imzalar her bir sınıfı iyi temsil eden pikseller olmalı ve homojen özellik göstermelidirler. Konumsal çözünürlükleri yüksek olan uydu görüntülerinde imzalar toplanırken bu problem fazla yaşanmamasına rağmen konumsal çözünürlükleri düşük görüntülerde bu duruma dikkat edilmelidir. Aksi takdirde sınıflar birbirine karışabilir ve bu durumda elde edilecek olan sınıflandırma sonucu yanlış veya eksik olacaktır.

İmzaların toplanmasından sonra uygun bir sınıflandırma algoritması yardımıyla sınıflandırma işlemi gerçekleştirilerek her bir piksel istatistiksel olarak en çok benzediği

sınıfa atanır. Eğer bazı piksellerin sınıfları belirlenemiyorsa bu pikseller bilinmeyen olarak etiketlenir. Bu piksellerin sınıfları daha sonra belirlenir.

Sınıflandırma işlemi gerçekleştirildikten sonra arazideki sınıflar tematik haritada gösterilir. Ardından sınıflandırma işleminin doğruluk analizi yapılır. Bu işlem hem görsel olarak hem de yazılımların kullandığı sınıflandırma analiz algoritmaları yardımıyla gerçekleştirilir. Elde edilen sınıflandırma sonuçları Coğrafi Bilgi Sistemlerine entegre edilerek veri tabanları oluşturulur ve bu alandaki başka çalışmalar için kaynak veri olarak kullanılabilir.

Arazideki sınıfların bilgisayara tanıtılması sırasında toplanan imzalar 2 sınıfa ayrılır. Parametrik imzalar piksellerin istatistiksel parametrelerine dayanırken parametrik olmayan imzalar istatistiksel parametreler yerine öznitelik uzayında (feature space) seçilen poligon veya dikdörtgenlere bağlıdır. Parametrik imzalar kullanılarak eğitilen karar kurallarına parametrik karar kuralı, parametrik olmayan imzalar kullanılarak eğitilen karar kurallarına parametrik olmayan karar kuralı denir. Parametrik karar kuralları kullanıldığında her piksel mutlaka bir sınıfa atanır. Çünkü parametrik karar uzayı süreklidir. Parametrik karar kuralları istatistiksel verilere dayanmadığı için görüntünün özelliklerinden bağımsızdır.

1.6.1.1. Parametrik Olmayan Karar Kuralları

1.6.1.1.1. Öznitelik Uzayı (Feature Space) Karar Kuralı

Bir görüntünün bantları koordinat sisteminin eksenleri gibi kabul edildiğinde görüntüdeki piksellerin gri değerlerinin koordinat olarak bu sistemde gösterimine öznitelik uzayı denir. Bu karar kuralının paralel kenar karar kuralından farkı aday piksellerin sınıflarının öznitelik uzayındaki dikdörtgenlerin içinde olup olmamasında değil de yine öznitelik uzayında kullanıcı tarafından oluşturulan poligonların içinde olup olmamasına göre belirlenmesidir. Aday piksel kullanıcı tarafından çizilen poligonlardan hangisinin içine düşüyorsa piksel o poligonun temsil ettiği sınıfa atanır.

Söz konusu pikselin birden fazla poligonun içinde kalması durumunda piksel ya ağırlığı büyük olan sınıfa atanır, ya parametrik bir kuralla sınıflandırılır ya da sınıfsız olarak bırakılır. Eğer piksel hiçbir poligonun içinde kalmıyorsa ya parametrik bir kuralla sınıflandırılır ya da sınıfsız olarak bırakılır (Erdas Imagine Field Guide).

Öznitelik Uzayı karar kuralının avantajları;

- Hızlı ve basit bir yöntemdir.
- Bu yöntem çoğu zaman parametrik bir sınıflandırma öncesi kabaca ön bir sınıflandırma işlemi için kullanılabilir
- Normal dağılımda olmayan sınıfların sınıflandırılmasında başarılıdır.
- Parametrik bilgiler ile birbirlerinden ayrılmaları mümkün olmayan bazı arazi detaylarının birbirinden ayrılarak doğru sınıflandırılmasında başarılı olabilir.

Dezavantajları

- Bir pikselin birden fazla sınıfa atanma riski vardır.
- Öznitelik uzayı yorumlama açısından zor bir uzaydır.

1.6.1.2. Parametrik Karar Kuralları

1.6.1.2.1. En Yakın Mesafe (Minimum Distance) Karar Kuralı

Bu karar kuralında aday piksel ile her bir imzaya ait ortalama vektör arasındaki spektral mesafe (öklit mesafesi) hesaplanır. Aday piksel ile imzaların ortalama vektörleri ile arasındaki mesafeler kıyaslanır ve kısa olan mesafe hangi mesafe ise piksel o imzanın temsil ettiği sınıfa atanır. Oldukça hızlı çalışan bu yöntemde her piksel spektral olarak en az bir tane imza ortalamasına yakın olacağından sınıfsız piksel kalmaz, dolayısıyla sınıfsız kalması daha mantıklı olabilecek olan pikseller dahi bir sınıfa atanır. Bu problemin önüne geçebilmek amacıyla ortalamadan çok uzakta olan pikseller ihmal edilir. Aynı zamanda bu yöntem sınıf içi çeşitliliği gözetmez. Oysa bazı kümeler küçük ve iç içeyken bazıları daha büyük ve dağınık olabilir. Öklit mesafesi formülü (Erdas Imagine Field Guide);

$$SD_{xyc} = \sqrt{\sum_{i=1}^n (\mu_{ci} - X_{xyi})^2} \quad (44)$$

şeklindedir. Burada n bant sayısını, i her bir bandı, c her bir sınıfı, X_{xyi} i ' inci bantta x, y konumundaki piksel değerini, μ_{ci} i ' inci banttaki c sınıfının ortalamasını ve SD_{xyc} ise x, y konumundaki piksel ile c sınıfının ortalaması arasındaki spektral mesafeyi göstermektedir.

1.6.1.2.2. Maksimum Benzerlik (Maximum Likelihood) Karar Kuralı

Bu yöntem bir pikselin bir olasılıkla bir sınıfa ait olması gerektiği prensibine dayanır. Bu karar kuralında bantların normal dağılımda olduğu ve bütün sınıfların olasılıklarının eşit olduğu varsayılır. Bu varsayıma göre sınıf deseninin dağılımı ortalama vektör ve kovaryans matrisi yardımıyla tanımlanabilir. Bütün pikseller için olasılıklar değerlendirilerek pikseller en olası sınıflara atanır. Düşey ekseninde olasılık ve yataydaki iki ekseninde ise görüntünün bantları yer almak üzere elde edilen çan şeklindeki yüzey olasılık yoğunluk fonksiyonu olarak adlandırılır. Eğer pikselin herhangi bir sınıfa ait olma olasılığı belirlenen bir eşiğin altında ise piksel “bilinmeyen” olarak sınıflandırılır (Ayhan vd., 2003). Eğer bütün sınıfların olasılıklarının eşit olmadığına dair önceden bir bilgi varsa sınıflara çeşitli ağırlıklar atanabilir. Maksimum benzerlik karar kuralının bu varyasyonuna Bayesian karar kuralı denir (Erdas Imagine Field Guide).

Olasılık yoğunluk fonksiyonu aşağıdaki şekildedir (Ayhan vd., 2003):

$$p(x|w_i) = (2\pi)^{-n/2} \times |S_x|^{-0.5} \times \exp[-0.5((x - m_i)^T S_x^{-1} (x - m_i))] \quad (45)$$

Bu formüldeki ortalama vektör (m_i) ve kovaryans matrisi (S_x) ise;

$$S_x = \frac{1}{K-1} \times \sum_{k=1}^K ((x - m_i)^T \times (x - m_i)) \quad (46)$$

$$m_i = \frac{1}{k} \times \sum_{k=1}^K X_k$$

şeklinde yazılır. Burada $p(x|w_i)$ olasılık dağılım fonksiyonunu, $|S_x|$ determinanı, m_i sınıf ortalamasını, n bant sayısını, S_x varyans-kovaryans matrisini, x piksel vektörünü ve K bir sınıfta bulunan toplam piksel sayısını gösterir.

Bayes teoremi sınıflandırma kuralına göre düzenlendiğinde;

$$\frac{p(x|w_i) * p(w_i)}{p(x)} > \frac{p(x|w_j) * p(w_j)}{p(x)} \quad j \neq i, \quad x \in w_i \quad (47)$$

formülüne ulaşılır. Buradaki w_i i' inci sınıfı göstermektedir. Formülde exponansiyel değer olmasından kaçınmak amacıyla her iki tarafında doğal logaritması alınırsa;

$$g_i(x) = \ln\{p(x|w_i) * p(w_i)\} = \ln p(x|w_i) + \ln p(w_i) \quad (48)$$

elde edilir (Ayhan vd., 2003). Olasılık yoğunluk fonksiyonu yerine yazılır ve bazı kısaltmalar uygulandığında sınıflandırma eşitliği elde edilir;

$$g_i(x) = -\ln|S_x| - (x - m_i)^T S_x^{-1} (x - m_i) \quad (49)$$

Maksimum Benzerlik karar kuralı yöntemi oldukça başarılı bir yöntemdir. Fakat bu yöntem kullanıldığında işlem uzun sürer ve başarısı görüntünün normal dağılımda olup olmamasına bağlıdır. Eğer görüntü normal dağılımda değilse paralel kenar veya en yakın mesafe karar kurallarının kullanılması daha mantıklıdır (Erdas Imagine Field Guide).

1.6.1.3. Destek Vektör Makineleri (Support Vector Machines) ile Sınıflandırma

Destek Vektör Makineleri Vladimir N. Vapnik tarafından geliştirilen ve temeli istatistiksel öğrenmeye dayalı bir kontrollü sınıflandırma yöntemidir. Destek Vektör Makinelerinin temel amacı sınıflandırma esnasında sınıfları birbirlerinden ayırt edebilecek olan en iyi fonksiyonu tahmin etmektir (Pal, 2005). Destek Vektör Makineleri (DVM) iki sınıfa ait örnek veriler arasındaki karar yüzeyinin her iki sınıfa olan uzaklığını maksimum dereceye çıkarır (Demir ve Ertürk, 2007).

1.6.1.3.1. Doğrusal Destek Vektör Makineleri

Bu yöntemde sınıflandırma ile birbirlerinden ayrılmak istenilen her iki veri grubunun sınırlarını belirlemek üzere birbirine paralel iki tane düzlem oluşturulur. Daha sonra ayırt etme işlemini gerçekleştirecek olan düzlem de bu iki paralel düzlemin tam ortasına yerleştirilir. Bu sayede her iki düzleme olan uzaklık maksimuma getirilmiş olunur. k sayıda iki sınıflı örnekten oluşan bir veri seti $\{x_i, y_i\}$, $i = 1, \dots, k$ şeklinde verilsin. Buradaki x , N boyutlu bir uzayı, $y = \{-1, +1\}$ ise sınıf etiketlerini göstermektedir. İki sınıf söz konusu iken sınıfların birbirlerinden ayrımını gerçekleştirecek olan düzlem şu eşitliklerle ifade edilebilir (Osuna et al., 1997);

$$\begin{aligned} w \cdot x_i + b &\geq 1 \\ w \cdot x_i + b &\leq -1 \end{aligned} \tag{50}$$

Burada w , hiper düzleme ait ağırlık vektörünü ve b ise hiper düzlemin orijinden olan uzaklığını göstermektedir. Bu durumda elde edilen hipotez uzayı şu şekilde olur;

$$f_{w,b} = \text{sign}(w \cdot x + b) \tag{51}$$

Eğer w ve b parametreleri aynı büyüklükte ölçeklenirse yukarıda yazılan karar düzlemi değişmeyecektir. Bu fazlalığı kaldırmak ve her bir karar yüzeyinin bir (w, b) çiftine karşılık gelmesini sağlamak amacıyla şu sınırlama getirilmiştir;

$$\min_{i=1, \dots, k} |w \cdot x_i + b| = 1 \tag{52}$$


Buradaki x_1, \dots, x_l veri setindeki noktaları göstermektedir. Bu eşitliği sağlayan hiper düzlemlere “kanonik (standart) hiper düzlemler” denir. Bütün karar düzlemleri bu hiper düzlemler ile temsil edilebilirler. Eğer (w, b) çiftleri için daha fazla sınırlamalar olmazsa standart hiper düzlemlerin VC (Vapnik-Chervonenkis) boyutu bağımsız parametre sayısına $(N + 1)$ eşit olur. Eğer bütün x_1, \dots, x_l noktaları N boyutlu kürede yer alıyorsa VC boyutu h aşağıdaki şekilde tanımlanır (Vapnik, 2000);

$$\{f_{w,b} = \text{sign}(w \cdot x + b) \mid \|w\| \leq A\} \quad (53)$$

$$h \leq \min\{[A^2], N\} + 1$$

Eğer x_1, \dots, x_l noktaları R yarıçaplı bir kürenin içinde yer alıyorsa $h \leq \min\{[R^2 A^2], N\} + 1$ şeklinde olur. Bir x noktasından hiper düzleme olan uzaklık (w, b) çiftine bağlı olarak şu şekilde ifade edilir;

$$d(x; w, b) = \frac{|w \cdot x + b|}{\|w\|} \quad (54)$$



Şekil 10. İki sınıf için optimum hiper düzlem (Çölkesen, 2009).

Tanımlanan standart hiper düzlem ile veri setindeki noktaların en yakını arasındaki uzaklık $1/\|w\|$ ' dir. Eğer $\|w\| \leq A$ ise standart hiper düzlem ile en yakın nokta arasındaki uzaklık $1/A$ ' dan büyük olmalıdır. Eğer örnek grupları doğrusal olarak ayrılabilirse, veriyi en doğru şekilde sınıflandıran standart hiper düzlemler arasında en iyisi minimum norma sahip veya eşit bir biçimde minimum $\|w\|^2$ olanıdır. Bu normun minimum olarak kalması VC boyutunun minimum olarak kalmasına neden olur. Doğrusal olarak ayrımın yapılabildiği durumda $\|w\|^2$ ' nin minimum olması, eğitim veri sınıfları arasında hiper düzleme olan dik çizgiler arasında hesaplanan uzaklığın bulunduğu ayırıcı hiper düzleme eşittir (Çölkesen, 2009). Hiper düzlemler arasındaki sınırın maksimum hale getirilmesi $i = 1, \dots, k$ olmak üzere;

$$y_i(w \cdot x_i + b) - 1 \geq 0 \quad (55)$$

eşitliğin çözümü ile mümkündür. Bu eşitlik Lagrange fonksiyonu ve Lagrange çarpanlarından faydalanılarak çözülür;

$$L(w, b, \lambda) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^k \lambda_i [y_i (w \cdot x_i + b) - 1] \quad (56)$$

Bu formüldeki $\lambda = \lambda_1, \dots, \lambda_k$ negatif olmayan Lagrange çarpanlarının vektörünü göstermektedir. Bu eşitliğin kısmi türevleri alınarak sıfıra eşitlenirse;

$$\frac{\partial L(w, b, \lambda)}{\partial w} = w^T - \sum_{i=1}^k y_i \lambda_i x_i = 0 \quad (57)$$

$$\frac{\partial L(w, b, \lambda)}{\partial b} = \sum_{i=1}^k y_i \lambda_i = 0$$

Bu denklem çiftlerinden;

$$w^T = \sum_{i=1}^k y_i \lambda_i x_i \quad (58)$$

$$\sum_{i=1}^k y_i \lambda_i = 0$$

eşitlikleri elde edilir. Burada elde edilen değerler ana denklemde yerine koyulursa;

$$L(w, b, \lambda) = \sum_i \lambda_i - \frac{1}{2} \sum_{i,j=1}^k \lambda_i \lambda_j y_i y_j (x_i \cdot x_j) \quad (59)$$

elde edilir. Sonuç olarak bu iki sınıfın ayrılması için kullanılması gereken karar kuralı;

$$f(x) = \text{sign}\left(\sum_{i=1}^k \lambda_i y_i (x \cdot x_i) + b\right) \quad (60)$$

şeklinde olur (Vapnik, 2000).

1.6.1.3.2. Doğrusal Olmayan Destek Vektör Makineleri

Bazı durumlarda birbirlerinden ayrt edilmek istenilen veriler doğrusal bir düzlem ile ayrılamaz. Bu gibi durumlarda doğrusal olarak ayrılmayan sınıflardaki her bir vektör \emptyset gibi doğrusal olmayan bir dönüşümle daha yüksek boyutlu bir uzaya dönüştürülür ve yeni uzayda doğrusal yolla ayrılabilme ihtimali güçlendirilir (Çölkesen, 2009). Doğrusal olarak ayrılabilen veriler için yazılmış olan (59) formülündeki iç çarpımların $(x_i \cdot x_j)$ yerine $\emptyset(x_i) \cdot \emptyset(x_j)$ yazılır. Bu eşitlik kullanılarak elde edilen karar fonksiyonu (Çölkesen, 2009);

$$f(x) = \text{sign}\left(\sum_{i=1}^k \lambda_i y_i \emptyset(x_i) \cdot \emptyset(x_j) + b\right) \quad (61)$$

şeklinde olmaktadır. Buradaki güçlük $\emptyset(x_i) \cdot \emptyset(x_j)$ iç çarpımın gerçekleşmesidir (Demir ve Ertürk, 2007). Bu güçlüğü ortadan kaldırmak amacıyla kernel fonksiyonları kullanılır (Marthur and Foody, 2008). Bu kernel fonksiyonlarının yardımıyla doğrusal olmayan sistemin doğrusal bir uzaya dönüştürülmesi işlemi gerçekleştirilir. Literatürde geçen kernel fonksiyonlarından bazıları şunlardır (ENVI Online Help);

Doğrusal Kernel Fonksiyonu;

$$K(x_i, x_j) = x_i x_j^T \quad (62)$$

Çok terimli Kernel fonksiyonu;


$$K(x_i, x_j) = (\gamma x_i x_j^T)^d \quad (63)$$

Radyal Taban Fonksiyonu;

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad (64)$$

Sigmoid Fonksiyon;

$$K(x_i, x_j) = \tanh(\gamma x_i x_j^T + r) \quad (65)$$



Şekil 11. Doğrusal olmayan verilerin yüksek boyutlu başka uzaya dönüşümü (Çölkesen, 2009).

1.6.1.3.3. Çok Sınıflı Destek Vektör Makineleri

Destek vektör makineleri ilk olarak iki sınıfı birbirinden ayırt edebilmek amacıyla geliştirilmiştir. Fakat günümüz şartlarında gerçekleştirilen birçok uygulamada sınıf sayısı ikiden fazla olmaktadır. Bu şekilde ikiden fazla sınıfın birbirlerinden ayrılabilmesi için çeşitli yaklaşımlar söz konusudur. Bunlardan ilki Bire Karşı Hepsini (One-Against-All) yaklaşımıdır (Liu and Zheng, 2005). M sınıflı bir uygulama probleminde N tane eğitim örneği $(\{x_1, y_1\}, \dots, \{x_N, y_N\})$ bulunduğu varsayıldığında $x_i \in R^m$ olmak üzere m boyutlu özellik vektörü ve $y_i \in \{1, 2, \dots, M\}$ olmak üzere sınıf etiketleridir. Bu yaklaşım M adet ikili destek vektör makine sınıflandırıcısı oluşturur. Bunlardan her biri bir sınıfı diğer bütün

sınıflardan ayırır. i ' inci destek vektör makinesi i ' inci sınıfa ait bütün eğitim örnekleri ile eğitilir ve pozitif etiketlerle etiketlenirler. Geriye kalanlar da negatif etiketlerle etiketlenirler. i ' inci karar fonksiyonu bu durumda;

$$f_i(x) = w_i^T \phi(x) + b_i \quad (66)$$

şeklinde olmaktadır. Bu yaklaşım gereği;

$$\frac{1}{2} (w^i)^T w^i + C \sum_{j=1}^l \xi_j^i \quad (67)$$

değeri minimize edilmelidir. $\frac{1}{2} (w^i)^T w^i$ değerinin minimize edilmesi $2/\|w^i\|$ değerinin maksimize edilmesi anlamına gelmektedir ki bu $2/\|w^i\|$ değeri her iki veri grubu arasındaki mesafedir. Veriler lineer bir şekilde ayrılamadığı zaman bir $C \sum_{j=1}^l \xi_j^i$ terimi tanıtlır. Bu terimin tanımlanmasının amacı eğitim hatalarını azaltmaktır.

Bir diğer yaklaşım ise Bire Karşı Bir (One-Against-One) yöntemidir (Breiman, 2001). Bu yöntemde de $k(k-1)/2$ adet sınıflandırıcı oluşturulur. Her bir sınıflandırıcı iki sınıfa ait verilerle eğitilir. i ' inci ve j ' inci sınıflardan elde edilen eğitim verileri için karar kuralı şu şekilde olur;

$$\min_{w^{ij}, b^{ij}, \xi^{ij}} \frac{1}{2} (w^{ij})^T w^{ij} + C \sum_t \xi_t^{ij} \quad (68)$$

Eğitim işlemlerinden sonra elde edilen her bir sınıflandırıcı test verisine uygulanır. Bu test verisindeki her bir noktaya eğitimler sonucu bir oy verilir. Sınıfı belirlenmek istenen her bir nokta için en çok oyu alan sınıf o noktanın sınıfını belirler. Bu yöntemle elde edilen sınıflandırıcı sayısı genellikle Bire Karşı Hepsi (One-Against-All) yöntemine oranla daha fazladır. Bunun yanında her bir sınıflandırıcı için ihtiyaç durulan eğitim veri vektörlerinin sayısı daha küçüktür. Bu yöntem Bire Karşı Hepsi metoduna göre daha simetriktir. Bu yöntemin dezavantajı sınıf sayısı arttıkça sınıflandırıcı sayısının da

artmasıdır (Pal, 2005). Örneğin 8 sınıf için 28 adet sınıflandırıcı kullanılmaktadır. Bu kadar sınıflandırıcının kullanılması sistem kaynaklarını oldukça fazla kullanacaktır.

Çok sınıflı karar fonksiyonu yaklaşımında ise sınıf etiketlerini belirlemek amacıyla birçok sınıflandırıcı oluşturmak yerine çok sınıf problemi direkt olarak çözülür (Pal, 2005; Lee et al., 2001; Weston and Watkins, 1998; Crammer and Singer, 2001; Schölkopf and Smola, 2002). Bu da sınıf karar fonksiyonunu bir sınırlama getirerek modifiye etmekle mümkün olmaktadır. Elde edilen fonksiyon sayesinde sınıflandırma işlemi gerçekleştirilirken eşzamanlı hesaplamalar yapılabilmektedir. Sözü edilen fonksiyon;

$$\min_{w,b,\xi} \left[\frac{1}{2} \sum_{i=1}^M \|w\|^2 + C \sum_{i=1}^k \sum_{r \neq y_i} \xi_i^r \right] \quad (69)$$

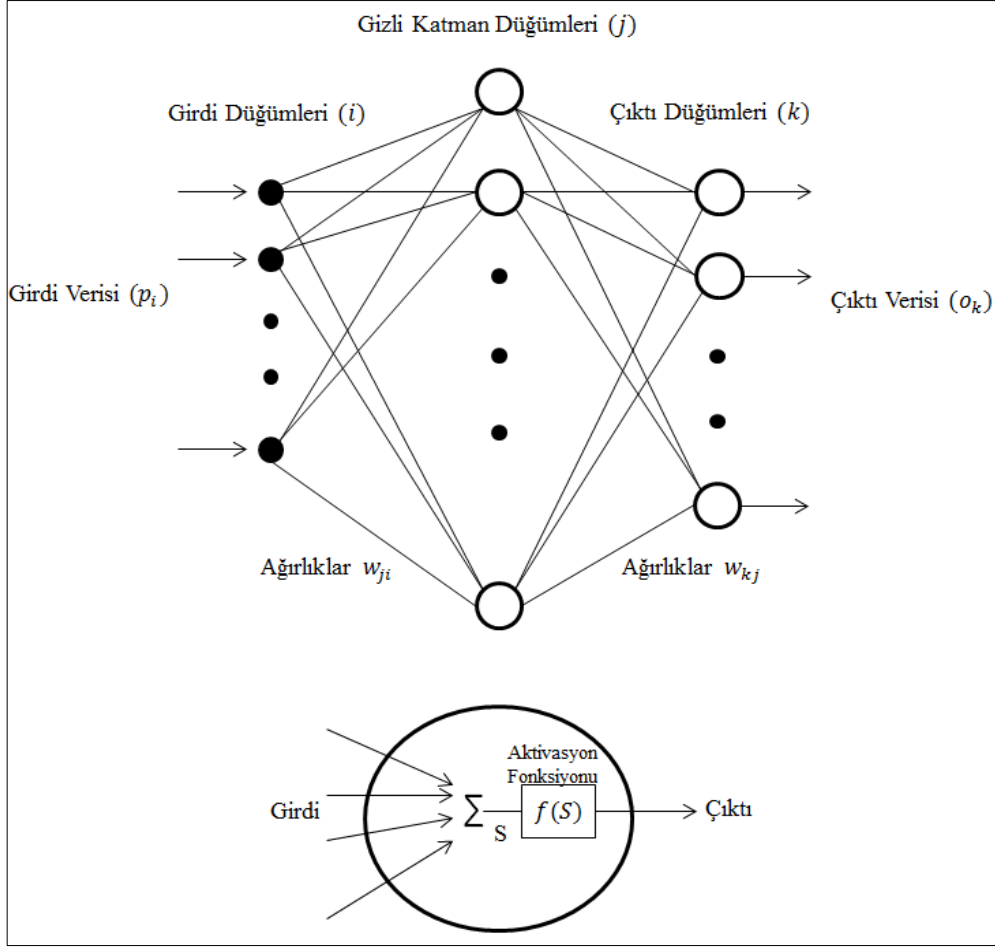
şeklinde, sınırlamalar ise;

$$\begin{aligned} w_{y_i} \cdot x_i + b_{y_i} &\geq w_r \cdot x_i + b_r + 2 - \xi_i^r \\ \xi_i^r &\geq 0 \quad i = 1, \dots, k \end{aligned} \quad (70)$$

şeklinde olmaktadır. Burada $y_i \in \{1, \dots, M\}$ veriye ait vektörlerin etiketlerini ve $r \in \{1, \dots, M\} \setminus y_i$ ise y_i hariç diğer sınıfların etiketlerini göstermektedir. Bu yaklaşımla elde edilen sonuçlar Bire Karşı Hepsini yöntemindekine oldukça benzerdir (Pal, 2005; Lee et al., 2001; Schölkopf and Smola, 2002). Bu metodda optimizasyon algoritması bütün destek vektörlerini aynı anda dikkate alır.

1.6.1.4. Yapay Sinir Ağları (Artificial Neural Network) ile Sınıflandırma

Son yıllarda kullanımı yaygınlaşan sınıflandırma yöntemlerinden biri de Yapay Sinir Ağlarıdır (YSA). İnsanlar tarafından göz ile beyin arasındaki koordinasyon ile başarılı bir şekilde doku analizi yapılabilmektedir. Bu prensipten yola çıkılarak yapay sinir ağlarında beyin basitçe modellenir. Yapay sinir ağları genellikle parametrik değildir. Dolayısıyla yapay sinir ağlarında verinin dağılımı ile ilgili istatistiksel birtakım kabullenmeler kullanılmamaktadır. YSA'nın performansı büyük ölçüde nasıl eğitildiklerine bağlıdır.



Şekil 12. Basit bir yapay sinir ağı (üstte) ve bu ağa ait örnek bir düğüm (altta) (Schowengerdt, 2007).

Eğitim sırasında sinir ağı eğitim verisindeki düzenlilikleri öğrenir ve bu öğrendiklerine göre kuralları inşa eder. Fakat kullanıcı ağın mimarisini oluşturmak zorundadır (Tso and Mather, 2009). Şekil 12’ de basit bir ağ gösterilmiştir. Bu ağın üç farklı katmanı vardır. En soldaki katman giriş verisi için basit bir ara yüzdür ve bu katmanda herhangi bir işlem gerçekleşmez. Bu katmandaki giriş verileri sınıflandırmada kullanılır. Buradaki her bir düğüm her bir banttaki eğitim piksellerinin çok bantlı vektörlerini içerir. Bunun yanında piksellerin komşuluk ilişkileri de bu düğümlerde depolanabilir. Ortadaki katman gizli katmandır ve bu katmanda işlemler gerçekleştirilir. En sağdaki katman ise çıktı katmanıdır. Sınıflandırma sonuçları bu katmanda üretilir (Schwengerdt, 2007). Her bir (j) gizli katman düğümünde giriş verisine (p_i) istenilen fonksiyonlar uygulanır ve h_j çıktısı üretilir. Aynı katmanlardaki sinirler arasında bağlantı

yoktur fakat komşu sinirlerle bağlantılıdır. Bu bağlantılar öğrenme aşamasında belirlenen ağırlıklarla (w_{jm}) ilişkilidirler. Gizli katman;

$$\text{gizli katman: } S_j = \sum_i w_{ji} p_i \quad \text{ve} \quad h_j = f(S_j) \quad (71)$$

formülü ile, çıktı katman ise (o_k) şu formülle belirlenir;

$$\text{çıkı katmanı: } S_k = \sum_j w_{kj} h_j \quad \text{ve} \quad o_k = f(S_k) \quad (72)$$

1.6.1.4.1. Geri Yayılım (Back Propagation)

En çok kullanılan yapay sinir ağı algoritmalarından bir tanesidir. Bu algoritmaya göre yapay sinir ağlarının sınıfları ayırt edebilmesi ağırlıklarla ilişkilidir. Geri yayılım algoritması ağın çıktısındaki bütün dokuların karesel ortalama hatalarını minimize eder (Rumelhart et al., 1986). Bu yöntem geri yayılım ve ileri yayılım olmak üzere iki adımdan oluşur. Eğitim boyunca her bir örnek girdi katmanına gelir ve burada bazı aktivasyon fonksiyonları kullanılarak ağ güncelleştirilir. Bu işleme ileri yayılım denilir. İleri yayılım işlemi bittikten sonra çıktı nöronlarındaki sonuçlar ile beklenen sonuçlar karşılaştırılır. Örneğin altı adet sınıf olduğu ve eğitim pikseli olan i ' nin 1. Sınıfa ait olduğu varsayılırsa sonuçta elde edilen nöronların "1 0 0 0 0 0" şeklinde olması beklenir. Bazı alışılmadık durumların haricinde beklenen sonuçlar ile elde edilen sonuçlar farklılık göstermektedirler. Bu farklılıklara ağ hatası denilmektedir. Bu hatalar çıktı katmanından başlayarak geriye doğru ağın tamamına dağıtılır. Buna ise geri yayılım denilmektedir. Bu şekilde ağ bütün sınıflara ait karakteristiklerin tamamını öğrenene kadar geri ve ileri yayılım işlemleri devam eder. Bu yöntem iteratif bir yöntem olup işlem adımları şu şekildedir (Schwengerdt, 2007):

- Her bir sınıf için eğitim pikselleri toplanır ve her bir k sınıfı d_k çıktı vektörü türetilir.
- Ağırlıklar 0 ve 1 arasında olmak üzere rastgele olarak verilir.

- Ağırlıkların güncellenmesi amacıyla frekans değeri her bir eğitim pikselinden sonra, her bir sınıf için bütün eğitim piksellerinden sonra ve bütün sınıflardaki tüm eğitim piksellerinden sonra olmak üzere bu üç seçenektten biri için ayarlanır.
- Bütün piksellerde uygulanmak üzere ileri yayılım işlemi gerçekleştirilir.
- Her bir eğitim pikseli için ileri yayılımdan sonra o çıktısı belirlenir.
- Bütün eğitim pikselleri kullanıldıktan sonra w_{kj} ağırlıkları dengelenir.

$$\Delta w_{kj} = LR \frac{\partial \varepsilon}{\partial w_{kj}} = LR \sum_{p=1}^P (d_k - o_k) \frac{d}{dS} f(S) \Big|_{S_k} h_j \quad (73)$$

Burada LR Öğrenim oranı (Learning Rate) parametresidir ve yakınsama hızını kontrol etmek için kullanılır.

- w_{ji} ağırlıkları dengelenir.

$$\Delta w_{ji} = LR \sum_{p=1}^P \left\{ \frac{d}{dS} f(S) \Big|_{S_j} \sum_k \left[(d_k - o_k) \frac{d}{dS} f(S) \Big|_{S_k} w_{kj} \right] p_i \right\} \quad (74)$$

- Bu işlemler belirlenen ε değeri önceden belirlenen eşik değerinden küçük oluncaya kadar devam eder.

1.6.1.5. İkili Kodlama (Binary Encoding) Sınıflandırma Yöntemi

Spektral olarak saf olan nesnelere toplanan verilere “endmember” denilmektedir. “Endmember” verileri veri kütüphaneleri içerisindeki verilerden, uydu görüntülerinden veya laboratuvar ortamında spektrometreler yardımıyla elde edilebilir. İkili kodlama sınıflandırıcısı veriyi ve “endmember” spektrumunu 0 ve 1’ li değerlerle kodlar. Eğer bir bant spektrum ortalamasının aşağısına düşüyorsa 0, yukarısında kalıyorsa 1 değerini alır (ENVI Online Help). Elde edilen sonuç 0 ve 1’ lerden oluşan bir vektördür. Bu şekilde

“endmember” için elde edilen ikili kodlanmış vektör ile görüntü için elde edilen ikili kodlanmış vektör eşleştirilir. Örneğin; bir “endmember” spektrumu için elde edilen ikili kod “0000 1100 0101 1101” ve görüntü için elde edilen ikili kod “1100 0110 1101 1111” olsun. Bu iki kod eşlendiğinde elde edilecek olan ikili kod “0011 0101 0111 1101” olacaktır. Buradaki eşleşme (doğruluk) $10/16 = \%62$ olmaktadır. Bu şekilde bir fonksiyon tarafından kodlanmış her bir referans spektrumu ve kodlanmış veri spektrumu karşılaştırılır ve sınıflandırılmış görüntü elde edilir.

1.6.1.6. Rastgele Orman (Random Forest) Sınıflandırma Yöntemi

Rastgele orman (RO) her biri rastgele bağımsız olarak örneklenen vektörlerin oluşturduğu sınıflandırıcılardan (ağaçlardan) meydana gelir. Bu sınıflandırıcılar girdi vektörlerindeki eğitim setlerinden elde edilir. Her ağaç en popüler sınıf için bir oy verir ve girdi vektörü sınıflandırılır (Breiman, 2001). RO yöntemi tüm ağaçlar arasında en çok oyu alan sınıfı seçer. Bir rastgele orman, torbalama ve rastgele alt uzay yöntemlerinden oluşturulur. Torbalama sınıflandırma doğruluğunu arttırmak için geliştirilmiştir (Breiman, 1996). N boyutlu bir eğitim setinde torbalama yöntemi $n < N$ olmak üzere her biri n boyutlu yeni veri setleri üretir. Verinin M sayıda özniteliği (Örn. bant sayısı) olduğu düşünülürse, ağacın her bir düğümü için m ($m < M$) tane öznitelik o düğümdeki en iyi ayrışmayı hesaplamak amacıyla rastgele olarak seçilir. Rastgele orman şekillendirildiğinde her örnek bütün ağaçlardan en fazla oyu alan sınıf olarak sınıflandırılır (Tso and Mather, 2009).

Bir karar ağacında öznitelik seçimi ve budama yöntemlerinin kullanılması söz konusudur. Bu özniteliklerin seçiminde kullanılan birçok yaklaşım bulunmaktadır. Karar ağaçlarında en fazla kullanılan öznitelik seçim yöntemleri bilgi kazanç oranı kriteri (Quinlan, 1993) ve Gini indeksidir (Breiman et al., 1984). Rastgele orman sınıflandırıcısı bunlardan Gini indeksini kullanır. Bu yöntemin temeli sınıflara ait olan özniteliklerin saflıklarının ölçülmesidir (Pal, 2005b).

Rastgele Orman sınıflandırıcısının en doğru sonuç veren öğrenme algoritmalarından bir tanesidir ve aynı zamanda binlerce girdi değişkeni ile çalışabilir. Buna karşılık rastgele ormanların yorumlanması insanlar için zordur (URL-1).

1.6.2. Kontrolsüz Sınıflandırma (Unsupervised Classification)

Kontrolsüz sınıflandırma kontrollü sınıflandırmadaki gibi imzalar toplanmadan otomatik kümeleme algoritmaları yardımıyla yapılan sınıflandırmadır. Kullanıcıdan bağımsız olan bu işlemde benzer spektral özellikteki pikseller gruplanarak her grup farklı renklerle ifade edilmek suretiyle tematik haritalar elde edilir. Bu yöntemde sınıflandırma öncesi arazi örtüsü tipinin bilinmesi gerekli değildir.

Literatüde en çok kullanılan kontrolsüz sınıflandırma algoritmalarından bir tanesi ISODATA (The Iterative Self-Organizing Data Analysis Technique) algoritmasıdır. Bu algoritmanın çalıştırılmasından önce algoritmaya 3 adet parametre tanıtılır. Bunlardan ilki maksimum küme sayısıdır (N). Buna maksimum sınıf sayısı da denilebilir. ISODATA işlemi rastgele N adet küme ortalaması belirlenerek başlar. Diğer parametre ise yakınsama eşik değeridir (T). Birbirini takip eden iterasyonlar piksellerin % T' si artık sınıf değiştirmeyinceye kadar devam eder. T yüzdesine ulaşıncaya algoritma otomatik olarak işlemi sonlandırır. Son parametre ise maksimum iterasyon sayısıdır (M). Bu değer girilmesinin nedeni bazı durumlarda iterasyon sayısı arttıkça yakınsama olmadığı için T değerine ulaşılamamasıdır. Bu gibi durumlar için maksimum iterasyon sayısı belirlenir. Bu sayede algoritma iterasyonlar ilerledikçe T değerine yaklaşamaz ise M değerine ulaştığında sonlandırılır.

İlk iterasyonda N adet başlangıç küme ortalaması seçilir. İşlem görüntünün sol üst köşesinden başlar ve sağa doğru taranarak görüntüdeki her piksel ile sınıfların ortalamaları arasındaki spektral mesafe hesaplanır. Hesaplanan spektral mesafeler kıyaslanır ve piksel spektral mesafesi en kısa olan sınıf ortalamasının temsil ettiği sınıfa atanır. Bu işlem görüntüdeki bütün pikseller için gerçekleştirildikten sonra en başa dönülür ve her bir küme için yeniden ortalamalar hesaplanır. Her bir aday piksel ile yeni sınıfların ortalamaları arasındaki spektral mesafeler hesaplanır. Tekrar hesaplanan yeni spektral mesafeler kıyaslanır ve pikselin gri değeri hangi sınıf ortalamasına daha yakınsa o sınıfa atanır. İşlem böyle devam eder ve artık tüm piksellerin % T' si yer değiştirmeyince veya maksimum iterasyon sayısına ulaşıncaya algoritma sonlanır (Erdas Imagine Field Guide).

ISODATA algoritması görüntüdeki mevcut spektral kümeleri bulmada oldukça başarılı bir yöntemdir. Dolayısıyla görüntüdeki sınıfların neler olabileceği hakkında bilgi sunabileceği için kontrollü sınıflandırma öncesi kullanılabilir. Bu yöntemin dezavantajları


olarak iterasyonların zaman alması ve pikseller arası konumsal homojenliđi dikkate almaması gösterilebilir (Erdas Imagine Field Guide).

Kontrolsüz sınıflandırma işleminden sonra sınıflandırmanın doğruluđu o bölgeye ait hava fotoğrafları, topoğrafik haritalar veya elde var olan başka verilerle kontrol edilmelidir. Kontrolsüz sınıflandırma işlemi kullanıcıdan bağımsız olduđu için kullanıcıdan kaynaklanabilecek hatalar ortadan kalkar.

2. YAPILAN ÇALIŞMALAR

2.1. Çalışma Bölgeleri, Kullanılan Uydu Görüntüleri ve Yazılımlar

Trabzon ilinin Sürmene ilçesi ve kent merkezi bu çalışma kapsamındaki uygulamalar için pilot bölgeler olarak seçilmiştir. Sürmene ilçesine ait 2012 tarihli Worldview-2 ve 2006 tarihli Landsat ETM+ çok bantlı görüntüleri kendi pankromatik bantlarıyla kaynaştırılmak üzere temin edilmiştir. Aynı zamanda kent merkezine ait 2003 tarihli Ikonos çok bantlı görüntüsü ile aynı uyduya ait pankromatik görüntü ve yine kent merkezi için 2003 tarihli Ikonos görüntüsü ve 2005 tarihli Quickbird pan-sharpened görüntüsü temin edilmiştir.



Şekil 13. Çalışma bölgeleri (URL-4).


Tablo 1. Uygulama kapsamında kullanılan uyduların teknik özellikleri (URL-5).

Quickbird	Ikonos	Landsat ETM+	Worldview-2
Yükseklik 450 km	Yükseklik 681 km	Yükseklik 705 km	Yükseklik 770 km
Pan 445 – 900 nm	Pan 450 – 900 nm	Pan 520 – 920 nm	Pan 400 – 800 nm
Ms 1: 450 – 520 nm 2: 520 – 600 nm 3: 630 – 690 nm 4: 760 – 890 nm	Ms 1: 450–520 nm 2: 520–610 nm 3: 640–720 nm 4: 770–880 nm	Ms 1: 450–520 nm 2: 520–600 nm 3: 630–690 nm 4: 760–900 nm 5: 1550–1750 nm 6: 10420–12500 nm 7: 2080–2350 nm	Ms 1: 400 – 450 nm 2: 450 – 510 nm 3: 510 – 580 nm 4: 585 – 625 nm 5: 630 – 690 nm 6: 705 – 745 nm 7: 770 – 895 nm 8: 860 – 1040 nm
Pan: 0.6 m Ms: 2.4 m	Pan: 1 m Ms: 4 m	Pan: 15 m Ms: 30 m	Pan: 0.46 m Ms: 1.84 m
11 bit	11 bit	8 bit	11 bit
16.5 km	11.3 km	185 km	16.4 km


Bu tez çalışması kapsamında yapılan bütün uygulamalar Erdas Imagine, ENVI ve Matlab yazılımları kullanılarak gerçekleştirilmiştir.

2.2. Gerçekleştirilen İşlemler


Bu çalışmada seçilen pilot bölgelere ait Worldview-2, Ikonos ve Landsat ETM+ çok bantlı görüntüleri kendi pankromatik görüntüleriyle, başka bir Ikonos görüntüsü ise Quickbird pan-sharpened görüntüsüyle 11 farklı görüntü kaynaştırma yöntemi kullanılarak kaynaştırılmıştır. Bu görüntü kaynaştırma yöntemleri Ehlers, Gram-Schmidt, CN, IHS, HPF, PCA, Multiplicative, Brovey, Dalgacık Dönüşümü, Kriter Tabanlı Görüntü Kaynaştırma Yöntemi ve literatüre yeni katılan yeni bir yöntemdir. Elde edilen kaynaştırılmış görüntüler ini spektral ve konumsal kalite tespiti amacıyla birtakım metrik değerleri hesaplanmıştır. Bu metrikler ise RASE, Spektral RMSE, Konumsal RMSE, Spektral ERGAS, Konumsal ERGAS, SAM ve SID metrikleridir. Daha sonra kaynaştırılan görüntüler tamamen aynı imzalar kullanılarak 6 farklı sınıflandırma algoritması yardımıyla sınıflandırılmıştır. Bu sınıflandırma algoritmaları ise En Yakın Mesafe, Maksimum Benzerlik, Yapay Sinir Ağları, Destek Vektör Makineleri, İkili Kodlama ve Rastgele Orman sınıflandırıcılarıdır. Worldview-2 çok bantlı görüntüsü ve aynı uyduya ait pankromatik bandın kaynaştırılmasıyla elde edilen kaynaştırılmış görüntüler su, fındık, çay, orman, gölge, kayalık, toprak, yol ve bina olmak üzere 9 sınıfa ayrılırken; Landsat ETM+ çok bantlı görüntüsü ve aynı uyduya ait pankromatik bandın kaynaştırılmasıyla elde edilen kaynaştırılmış görüntüler su, orman, toprak ve kent olmak üzere 4 sınıfa; Ikonos çok bantlı çok bantlı görüntüsü ve aynı uyduya ait pankromatik bandın kaynaştırılmasıyla elde edilen kaynaştırılmış görüntüler gölge, yol, bina ve yeşil alan olmak üzere 4 sınıfa ayrılmıştır. Kent merkezine ait başka bir Ikonos görüntüsünün Quickbird pan-sharpened görüntüsünden elde edilen pankromatik görüntüyle kaynaştırılmasıyla elde edilen kaynaştırılmış görüntüler ise bina, yol, gölge ve yeşil alan olmak üzere yine 4 sınıfa ayrılmıştır. Sınıflandırma işlemlerinin doğruluklarının tespit edilebilmesi amacıyla sınıflandırılan her kaynaştırılmış görüntü için 450 adet referans noktası kullanılmıştır. Bu 450 adet noktanın sınıflandırma sonrası elde edilen sınıfları ile arazideki gerçek sınıfları kıyaslanarak genel sınıflandırma doğruluklarına ulaşılmıştır. Arazideki sınıfların birbirlerinden ayrılabilirlikleri irdelenirken kullanıcı doğrulukları (user' s accuracy) baz alınmıştır. Kullanıcı doğrulukları ekler bölümünde verilmiştir. Elde edilen sınıflandırma sonuçları ve istatistiki tüm veriler 3. bölümünde detaylı olarak verilmiştir. Uygulama kapsamında kullanılan Worldview-2, Landsat ETM+, Ikonos ve Quickbird görüntülerinin tamamı aşağıda gösterilmiştir.



Şekil 14. Orijinal Worldview-2 (WV2) çok bantlı görüntüsü (üstte) ve aynı uyduya ait pankromatik bant (altta)



Şekil 15. Orijinal Landsat ETM+ çok bantlı görüntüsü (üstte) ve aynı uyduya ait pankromatik bant (altta)



Şekil 16. Orijinal Ikonos çok bantlı görüntüsü (solda) ve aynı uyduya ait pankromatik bant (sağda)



Şekil 17. Orijinal Ikonos çok bantlı görüntüsü (solda) ve Quickbird pan-sharpened görüntüsünden elde edilen pankromatik bant (QBPan) (sağda)

3. BULGULAR VE İRDELEMELER

3.1. Nicel Değerlendirme

Bu bölümde kaynaştırılmış görüntülerin spektral ve konumsal kalitelerinin değerlendirilmesini sağlamak amacıyla birtakım istatistiksel hesaplamalara yer verilmiştir. İyi bir kaynaştırma yöntemi;

- orijinal çok bantlı görüntünün bantlarına ait ortalama ve standart sapma değerlerini korumalıdır.
- ürettiği kaynaştırılmış görüntünün bantları ile kaynaştırmada kullanılan çok bantlı görüntünün bantları arasındaki korelasyonların yüksek olmasını sağlamalıdır.
- spektral ve konumsal kalite ölçen metriklerden iyi denilebilecek düzeyde puanlar almalıdır. Fakat burada metrik değerlerinin tutarsız ve yanıltıcı sonuçlar verebildiği göz önünde bulundurulmalıdır.
- orijinal çok bantlı görüntünün bantları arasındaki korelasyon değerlerinin kaynaştırılmış görüntünün bantları arasında da olmasını sağlamalıdır.

Tablo 2' de orijinal Worldview-2 çok bantlı görüntüsünün ve çok bantlı görüntünün kendi pankromatik bandıyla kaynaştırılmasıyla elde edilen kaynaştırılmış görüntülerin bantlarının ortalama ve standart sapma değerleri görülmektedir. Bu bölümdeki tabloların hücrelerindeki değerlerin ilki ortalama, ikincisi ise standart sapma değerini göstermektedir. Tablo 2' ye göre orijinal çok bantlı görüntünün bantlarına ait ortalama değerlerini en iyi koruyan kaynaştırma yöntemleri Dalgacık Dönüşümü, HPF, Kriter Tabanlı görüntü kaynaştırma yöntemi, yeni yöntem ve Gram-Schmidt yöntemidir. PCA, Ehlers, Brovey, CN ve Multiplicative görüntü kaynaştırma yöntemleri çok bantlı görüntünün bant ortalamalarını koruyamamaktadır. Yine bu tabloya göre HPF ve Kriter Tabanlı görüntü kaynaştırma yöntemi ile elde edilen kaynaştırılmış görüntülerin bantlarının standart sapma değerleri orijinal görüntünün bantlarının standart sapma değerlerine daha yakındır. Multiplicative, Brovey ve CN yöntemleri ise standart sapma değerlerini en fazla değiştiren yöntemlerdir.

Tablo 2. Worldview-2 çok bantlı görüntüsü ile aynı uyduya ait pankromatik bantın kaynaştırılması ile elde edilen görüntülerin bantlarının ortalama ve standart sapma değerleri

	B1	B2	B3	B4	B5	B6	B7	B8
ORJ	332-35	188-37	232-58	182-75	74-43	378-184	384-219	580-335
CN	291-73	167-57	205-80	161-86	66-49	313-149	316-177	473-264
GS	332-33	188-34	232-59	182-80	74-46	378-174	384-202	580-294
DD	332-36	188-38	232-60	182-75	74-43	378-185	384-221	580-343
PCA	244-33	91-35	150-59	157-76	59-43	53-53	77-77	110-110
HPF	332-35	188-37	231-58	182-75	73-43	377-184	384-218	580-334
EH	419-33	283-29	231-48	194-63	242-37	564-140	1212-91	821-78
IHS		184-40	226-58		71-40			
KT	332-39	188-39	232-60	182-75	74-44	378-182	385-218	580-333
YY	331-38	188-38	231-59	182-76	73-44	377-190	384-224	579-342
BR	288-32	160-24	200-36	160-44	64-32	312-76	312-88	472-132
MUL	325-31	185-23	232-35	189-41	79-22	412-68	419-72	632-109

Landsat ETM+ çok bantlı görüntüsünün ve Landsat ETM+ görüntüsünün pankromatik bantıyla kaynaştırılmasıyla elde edilen kaynaştırılmış görüntülerin bantlarına ait ortalama ve standart sapma değerleri Tablo 3' de gösterilmiştir. Bu değerlere göre orijinal çok bantlı görüntünün bant ortalamasını en iyi koruyan görüntü kaynaştırma yöntemlerinin HPF, Dalgacık Dönüşümü, Gram-Schmidt, IHS ve Kriter Tabanlı Görüntü Kaynaştırma yöntemi oldukları görülmektedir. Bu konuda en başarısız kaynaştırma yöntemleri ise PCA, Ehlers ve Multiplicative yöntemleridir. Aynı zamanda orijinal görüntünün bantlarına ait standart sapma değerlerini en iyi korumayı başaran görüntü kaynaştırma yöntemleri HPF, Dalgacık Dönüşümü, Kriter Tabanlı Görüntü Kaynaştırma yöntemi ve IHS yöntemleridir. Ehlers, Multiplicative ve PCA yöntemleri ise en başarısız yöntemlerdir.

Ikonos çok bantlı görüntüsünün ve Ikonos görüntüsünün pankromatik bantıyla kaynaştırılmasıyla elde edilen kaynaştırılmış görüntülerin bantlarına ait ortalama ve standart sapma değerleri Tablo 4' de gösterilmiştir. Buna göre bantlarının ortalaması orijinal görüntünün bantlarının ortalamasına en yakın olan kaynaştırılmış görüntüler Gram-Schmidt, HPF, Dalgacık Dönüşümü ve Kriter Tabanlı Görüntü Kaynaştırma yöntemleriyle elde edilen kaynaştırılmış görüntülerdir. Diğer yandan orijinal çok bantlı Ikonos görüntüsünün bantlarına ait standart sapma değerlerini en başarılı koruyan kaynaştırma

yöntemleri Gram-Schmidt, Dalgacık Dönüşümü ve HPF yöntemleridir. Multiplicative, Brovey ve Ehlers yöntemleri standart sapma değerlerini koruyamamaktadır.

Tablo 3. Landsat ETM+ çok bantlı görüntüsü ile aynı uyduya ait pankromatik bandın kaynaştırılması ile elde edilen görüntülerin bantlarının ortalama ve standart sapma değerleri

	B1	B2	B3	B4	B5	B6
ORJ	80-7	58-10	43-14	73-49	65-43	34-21
CN	63-20	47-20	36-18	71-56	65-43	34-21
GS	80-7	58-9	43-12	73-54	65-45	34-20
DD	80-7	58-10	43-14	73-49	65-43	34-21
PCA	72-7	77-9	66-13	224-32	200-28	93-16
HPF	80-7	57-10	43-14	73-49	65-43	34-21
EH	91-7	57-9	38-12	36-6	225-5	170-6
IHS	80-7	57-11	43-14			
KT	80-9	57-10	43-14	73-49	65-43	34-21
YY	67-9	52-6	39-9	87-58	76-50	37-22
BR	53-13	40-15	28-13	72-57	53-39	26-18
MUL	68-34	52-31	40-29	84-70	74-61	37-31

Tablo 4. Ikonos çok bantlı görüntüsü ile aynı uyduya ait pankromatik bandın kaynaştırılması ile elde edilen görüntülerin bantlarının ortalama ve standart sapma değerleri

	B1	B2	B3	B4
ORJ	368-103	405-157	355-177	344-185
CN	333-157	367-204	324-211	314-213
GS	368-102	405-156	355-179	344-187
DD	365-102	402-158	351-177	339-186
PCA	406-115	466-178	424-202	414-210
HPF	368-103	405-158	355--178	344-186
EH	479-100	475-141	511-149	1735-31
IHS	370-121	403-159	349-170	
KT	369-119	406-167	355-183	344-188
YY	338-103	400-172	379-204	372-208
BR	83-38	91-51	81-52	78-53
MUL	540-600	623-778	570-785	558-778

Tablo 5’ de Ikonos çok bantlı görüntüsü ve QBPan görüntüsünün kaynaştırılmasıyla elde edilen görüntülerin bant ortalamaları ve standart sapmaları görülmektedir. Bu tabloya göre orijinal çok bantlı Ikonos görüntüsünün bant ortalama değerlerini korumada en başarılı kaynaştırma yöntemleri HPF, Gram-Schmidt, Dalgacık Dönüşümü ve Kriter Tabanlı Görüntü Kaynaştırma yöntemleridir. Ehlers, PCA, Brovey, Multiplicative ve IHS kaynaştırma yöntemleri bant ortalamasını koruyamamaktadırlar. Standart sapma değerlerinin orijinal çok bantlı görüntü ile benzer olmasını sağlayan kaynaştırma yöntemleri HPF, Dalgacık Dönüşümü ve Gram-Schmidt kaynaştırma yöntemleridir. Multiplicative, Ehlers, PCA, Brovey ve yeni yöntem orijinal çok bantlı görüntünün standart sapma değerlerini koruyamamıştır.

Tablo 5. Ikonos çok bantlı görüntüsü ile QBPan görüntüsünden elde edilen pankromatik görüntünün kaynaştırılması ile elde edilen görüntülerin bantlarının ortalama ve standart sapma değerleri

	B1	B2	B3	B4
ORJ	346-81	377-124	319-141	345-152
CN	375-144	401-156	333-149	359-163
GS	346-80	377-123	319-144	345-151
DD	343-81	374-124	316-141	342-152
PCA	422-142	500-227	460-263	486-265
HPF	346-81	377-124	319-141	345-151
EH	1677-2	512-4	462-3	359-6
IHS	308-118	375-127	353-126	
KT	348-98	378-132	320-144	346-152
YY	346-127	376-139	320-137	346-144
BR	93-35	100-38	83-37	90-41
MUL	513-272	567-343	489-341	524-341

Worldview-2 çok bantlı görüntüsü ve pankromatik bandının 11 farklı kaynaştırma yöntemi kullanılarak kaynaştırılmasıyla elde edilen kaynaştırılmış görüntüler ile orijinal Worldview-2 görüntüsünün bantları arasındaki korelasyonlar Tablo 6’ da gösterilmiştir. Bu tabloya göre orijinal görüntü ile arasında en yüksek korelasyon bulunan kaynaştırılmış görüntü HPF yöntemiyle kaynaştırılan görüntüdür, yani orijinal çok bantlı görüntünün spektral yapısını en iyi koruyan görüntü kaynaştırma yönteminin HPF yöntemi olduğunu görülmektedir. HPF yöntemini Ehlers ve Kriter Tabanlı Görüntü kaynaştırma yöntemi takip

etmektedir. Orijinal görüntü ile arasında en düşük korelasyon olan kaynaştırılmış görüntüler ise PCA, Multiplicative ve IHS görüntü kaynaştırma yöntemidir. Bu kaynaştırma yöntemleri spektral yapıyı korumada başarılı olamamaktadırlar.

Tablo 6. Worldview-2 çok bantlı görüntüsü ve pankromatik bandının kaynaştırılmasıyla elde edilen kaynaştırılmış görüntülerin bantları ile orijinal Worldview-2 görüntüsünün bantları arasındaki korelasyonlar

	HPF-ORJ	EH-ORJ	MUL-ORJ	GS-ORJ	BR-ORJ	PCA-ORJ	CN-ORJ	DD-ORJ	KT-ORJ	IHS-ORJ	YY-ORJ
B1	0,97	0,88	0,46	0,97	0,85	0,76	0,81	0,92	0,86		0,89
B2	0,96	0,95	0,57	0,97	0,92	0,75	0,91	0,92	0,92	0,76	0,95
B3	0,99	0,95	0,71	0,97	0,91	0,89	0,91	0,93	0,94	0,89	0,94
B4	0,94	0,94	0,84	0,97	0,91	0,95	0,93	0,95	0,96		0,95
B5	0,96	0,95	0,84	0,97	0,94	0,95	0,94	0,95	0,95	0,76	0,95
B6	0,97	0,96	0,89	0,85	0,93	-0,53	0,93	0,88	0,97		0,94
B7	0,96	0,98	0,92	0,86	0,95	-0,48	0,95	0,87	0,98		0,96
B8	0,97	0,98	0,92	0,86	0,95	-0,56	0,96	0,88	0,98		0,96
ORT	0,96	0,95	0,77	0,93	0,92	0,34	0,92	0,91	0,94	0,80	0,94

Tablo 7. Landsat ETM+ çok bantlı görüntüsü ve pankromatik bandının kaynaştırılmasıyla elde edilen kaynaştırılmış görüntülerin bantları ile orijinal Landsat ETM+ görüntüsünün bantları arasındaki korelasyonlar

	HPF-ORJ	EH-ORJ	MUL-ORJ	GS-ORJ	BR-ORJ	PCA-ORJ	CN-ORJ	DD-ORJ	KT-ORJ	IHS-ORJ	YY-ORJ
B1	0,92	0,59	-0,12	0,95	-0,23	0,71	-0,25	0,88	0,70	0,42	0,45
B2	0,93	0,80	0,75	0,93	0,67	0,32	0,68	0,87	0,81	0,83	0,84
B3	0,93	0,90	0,77	0,93	0,73	0,50	0,76	0,84	0,81	0,50	0,86
B4	0,96	0,98	0,96	0,95	0,97	-0,88	0,98	0,99	0,97		0,97
B5	0,96	0,98	0,96	0,94	0,96	-0,92	0,99	0,99	0,97		0,97
B6	0,95	0,96	0,91	0,92	0,91	-0,44	0,98	0,95	0,91		0,94
ORT	0,94	0,87	0,71	0,93	0,67	-0,12	0,69	0,92	0,86	0,58	0,84

Landsat ETM+ çok bantlı görüntüsü ve pankromatik bandının uygulama kapsamındaki kaynaştırma yöntemi kullanılarak kaynaştırılmasıyla elde edilen kaynaştırılmış görüntülerin bantları ile orijinal Landsat ETM+ görüntüsünün bantları arasındaki korelasyonlar Tablo 7' de gösterilmiştir. Bu korelasyon değerlerine göre HPF

yöntemi ile elde edilen kaynaştırılmış görüntü ortalama % 94 korelasyonla, Gram-Schmidt yöntemi ile kaynaştırılan görüntü ortalama % 93 korelasyonla orijinal görüntüye spektral olarak oldukça benzemektedir. Bu yöntemleri % 92 ortalama ile Dalgacık Dönüşümü kaynaştırma yöntemi ile elde edilen kaynaştırılmış görüntü takip etmektedir. Multiplicative, PCA, IHS, Brovey ve CN görüntü kaynaştırma yöntemleri ile elde edilen kaynaştırılmış görüntüler sahip oldukları düşük korelasyon ile başarısız olmuşlardır.

Tablo 8. İkonos çok bantlı görüntüsü ve pankromatik bandının kaynaştırılmasıyla elde edilen kaynaştırılmış görüntülerin bantları ile orijinal İkonos görüntüsünün bantları arasındaki korelasyonlar

	HPF-ORJ	EH-ORJ	MUL-ORJ	GS-ORJ	BR-ORJ	PCA-ORJ	CN-ORJ	DD-ORJ	KT-ORJ	IHS-ORJ	YY-ORJ
B1	0,83	0,60	0,75	0,74	0,63	0,74	0,59	0,77	0,78	0,67	0,83
B2	0,83	0,73	0,75	0,73	0,71	0,73	0,70	0,78	0,85	0,68	0,83
B3	0,83	0,78	0,74	0,73	0,76	0,73	0,77	0,78	0,88	0,48	0,83
B4	0,82	0,77	0,72	0,74	0,76	0,73	0,79	0,77	0,88		0,82
ORT	0,83	0,72	0,74	0,74	0,71	0,73	0,71	0,77	0,84	0,61	0,83

Tablo 8’ de İkonos çok bantlı ve pankromatik görüntülerinin kaynaştırılması ile elde edilen görüntülerin bantları ile orijinal çok bantlı görüntünün bantları arasındaki korelasyon değerleri gösterilmiştir. Bu tablo incelendiğinde Kriter Tabanlı Görüntü Kaynaştırma yöntemi ile kaynaştırılan görüntünün bantları ile orijinal görüntünün bantları arasındaki korelasyon değerlerinin en yüksek olduğu (% 84) görülmektedir. Kriter Tabanlı Görüntü Kaynaştırma yöntemini % 83 ile HPF yöntemi ve yeni yöntem takip etmektedir. IHS, Brovey, Ehlers, PCA ve CN yöntemleri korelasyon dengesini sağlayamamışlardır.

İkonos çok bantlı görüntüsü ve QBPan görüntülerinin uygulama kapsamındaki kaynaştırma yöntemleriyle kaynaştırılmasıyla elde edilen görüntülerin bantları ile orijinal çok bantlı İkonos görüntüsünün bantları arasındaki korelasyon değerleri Tablo 9’ da görülmektedir. Kriter Tabanlı Görüntü Kaynaştırma yöntemi ile HPF kaynaştırma yöntemleri ile elde edilen kaynaştırılmış görüntülerin bantları ile orijinal İkonos görüntüsünün bantları arasındaki korelasyonlar diğer yöntemlere göre daha fazla olduklarından bu iki yöntem görüntü kaynaştırmada bu veri seti için en başarılı yöntemlerdir. Brovey, PCA, IHS ve CN kaynaştırma yöntemleri ise sahip oldukları düşük korelasyon değerlerinden dolayı kaynaştırmada başarısız olmuşlardır.

Tablo 9. İkonos çok bantlı görüntüsü ve QBPan görüntüsünün kaynaştırılmasıyla elde edilen kaynaştırılmış görüntülerin bantları ile orijinal İkonos görüntüsünün bantları arasındaki korelasyonlar

	HPF-ORJ	EH-ORJ	MUL-ORJ	GS-ORJ	BR-ORJ	PCA-ORJ	CN-ORJ	DD-ORJ	KT-ORJ	IHS-ORJ	YY-ORJ
B1	0,73	0,30	0,61	0,42	0,13	0,38	0,11	0,69	0,70	0,39	0,19
B2	0,72	0,52	0,67	0,37	0,31	0,36	0,31	0,70	0,80	0,20	0,37
B3	0,73	0,58	0,72	0,39	0,52	0,37	0,54	0,71	0,85	-0,08	0,46
B4	0,71	0,63	0,69	0,47	0,54	0,38	0,58	0,68	0,84		0,47
ORT	0,72	0,51	0,67	0,41	0,38	0,37	0,38	0,69	0,79	0,17	0,37

Tablo 10. Worldview-2 çok bantlı görüntüsü ve aynı uyduya ait pankromatik görüntünün kaynaştırılmasıyla elde edilen kaynaştırılmış görüntülerin metrik değerleri

METRİKLER	RASE %	Spek. RMSE	SID	Spek. ERGAS	SAM	Kon. RMSE	Kon. ERGAS
CN	4,368	80,626	0,004	5,707	0,029	9,188	16,367
GS	4,443	82,018	0,055	4,745	0,129	194,060	19,430
DD	4,264	78,701	0,221	4,743	0,109	216,858	21,712
PCA	43,259	798,514	0,389	43,088	0,564	917,288	91,840
HPF	4,112	75,896	0,044	5,215	0,095	204,022	20,427
EH	18,304	337,865	0,417	29,274	0,511	422,246	42,276
IHS	37,917	140,038	0,704	44,313	0,641	109,272	10,940
KT	1,998	36,876	0,000	2,895	0,000	209,298	20,955
YY	17,397	321,128	0,012	23,894	0,000	224,421	22,469
BR	17,806	328,677	0,004	24,324	0,029	229,187	22,947
MUL	6,690	123,484	0,004	12,183	0,003	255,732	25,604

Worldview-2 çok bantlı görüntüsünün kendi pankromatik bandıyla bu çalışma kapsamındaki kaynaştırma yöntemleri kullanılarak elde edilen kaynaştırılmış görüntülerin metrik değerleri Tablo 10' da gösterilmiştir. Bu tablo incelendiğinde HPF, Kriter Tabanlı Görüntü Kaynaştırma yöntemi, Dalgacık Dönüşümü yöntemi ve Gram-Schmidt yönteminin görüntü kaynaştırma işlemi sırasında orijinal çok bantlı görüntünün spektral yapısını korumadaki başarıları görülmektedir. Kriter Tabanlı Görüntü Kaynaştırma yöntemi RASE, Spektral RMSE, SID, Spektral ERGAS ve SAM metriklerinden sırasıyla 1,998,

36,876, 0, 2,895 ve 0 değerlerini alarak spektral yapıyı korumadaki başarısını göstermiştir. HPF yöntemi RASE, Spektral RMSE, SID, Spektral ERGAS ve SAM metriklerinden sırasıyla 4,112, 75,896, 0,044, 5,215 ve 0,095 değerlerini alarak spektral yapıyı iyi koruyan diğer bir yöntem olarak belirlenmiştir. Bu kaynaştırma yöntemlerinin yanı sıra Gram-Schmidt ve Dalgacık Dönüşümü ile kaynaştırılmış görüntüler de renk kalitesi bakımından oldukça iyi sonuçlar vermektedir. Bu metrik değerlerine göre spektral yapıyı en çok bozan görüntü kaynaştırma yöntemi PCA yöntemi olarak belirlenmiştir. PCA yöntemini Ehlers yöntemi takip etmektedir. Tablo 10 incelendiğinde pankromatik görüntüdeki konumsal detayları kaynaştırılmış görüntüye en iyi aktaran yöntemin 10,940 değeriyle IHS yöntemi olduğu belirlenmiştir. CN ve HPF yöntemleri de konumsal detay kalitesi bakımından oldukça kaliteli kaynaştırılmış görüntüler üretmektedir. Konumsal ERGAS metrik değerine göre konumsal detayı aktarmada en başarısız yöntem PCA yöntemi olarak görülmektedir.

Tablo 11. Landsat ETM+ çok bantlı görüntüsü ve aynı uyduya ait pankromatik görüntünün kaynaştırılmasıyla elde edilen kaynaştırılmış görüntülerin metrik değerleri

METRİKLER	RASE %	Spek. RMSE	SID	Spek. ERGAS	SAM	Kon. RMSE	Kon. ERGAS
CN	5,036	16,479	0,044	12,814	0,108	22,965	20,938
GS	3,181	10,408	0,041	8,889	0,065	28,998	26,435
DD	3,964	12,973	0,175	11,122	0,089	31,336	28,570
PCA	30,145	98,643	0,415	79,605	0,551	103,418	94,290
HPF	2,580	8,443	0,024	7,355	0,058	28,034	25,560
EH	27,666	90,530	0,909	96,893	0,784	89,252	81,375
IHS	35,677	54,757	0,414	43,969	0,506	52,690	48,040
KT	2,840	9,293	0,008	8,796	0,000	29,419	26,823
YY	4,311	14,106	0,034	5,692	0,125	31,975	14,577
BR	17,585	57,542	0,007	47,046	0,045	51,460	46,918
MUL	15,399	50,388	0,007	40,990	0,045	44,196	40,295

Tablo 11' de Landsat ETM+ çok bantlı görüntüsünün kendi pankromatik bandıyla kaynaştırılmasıyla elde edilen kaynaştırılmış görüntülerinin metrik değerleri görülmektedir. HPF yöntemi ile elde edilen kaynaştırılmış görüntü sırasıyla 2,580, 8,443 ve 7,355 değerleriyle RASE, Spektral RMSE ve Spektral ERGAS metriklerinde birinci sırayı

almaktadır. Çok bantlı görüntünün renk yapısını fazla bozmayan diğer yöntemlerin Gram-Schmidt, Dalgacık Dönüşümü ve Kriter Tabanlı Görüntü Kaynaştırma yöntemleri oldukları görülmektedir. PCA, Ehlers ve IHS yöntemleri ise bu metriklerden oldukça düşük değerler almışlardır.

Tablo 12. İkonos çok bantlı görüntüsü ve aynı uyduya ait pankromatik görüntünün kaynaştırılmasıyla elde edilen kaynaştırılmış görüntülerin metrik değerleri

METRİKLER	RASE %	Spek. RMSE	SID	Spek. ERGAS	SAM	Kon. RMSE	Kon. ERGAS
CN	11,452	139,239	0,003	9,448	0,013	50,974	3,805
GS	9,565	116,289	0,009	8,003	0,056	74,411	5,555
DD	8,806	107,060	0,017	7,374	0,075	114,246	8,528
PCA	11,557	140,508	0,018	9,678	0,078	209,661	15,651
HPF	7,665	93,191	0,010	6,422	0,000	85,170	6,358
EH	58,684	713,482	0,555	51,707	0,667	720,831	53,809
IHS	15,615	139,401	0,130	9,384	0,177	86,821	6,481
KT	7,188	87,390	0,006	5,973	0,000	142,669	10,650
YY	8,566	104,148	0,016	7,196	0,081	116,700	8,711
BR	25,716	312,650	0,010	21,227	0,046	289,906	21,641
MUL	54,413	661,555	0,010	45,136	0,046	625,087	46,662

İkonos çok bantlı görüntüsünün pankromatik bandıyla uygulama kapsamındaki kaynaştırma yöntemleri kullanılarak kaynaştırılmasıyla elde edilen kaynaştırılmış görüntülerin metrik değerleri Tablo 12’ de gösterilmiştir. Daha önce de değinildiği gibi bu metrik değerlerinden RASE, Spektral RMSE, SID, SAM ve Spektral ERGAS metrikleri kaynaştırılmış görüntülerin spektral kalitelerinin değerlendirilmesi için kullanılmaktadır. Bu tabloya göre Kriter Tabanlı Görüntü Kaynaştırma yöntemi Spektral RMSE, Spektral ERGAS, SAM ve RASE metriklerinden sırasıyla 87,390, 5,973, 0,000 ve 7,188 değerlerini alarak spektral yapıyı en iyi koruyan yöntem olmuştur. Bu yöntemi RASE, Spektral RMSE, SID, Spektral ERGAS ve SAM metriklerinden sırasıyla 7,665, 93,191, 0,010, 6,422, 0,000 değerlerini alarak spektral yapıyı en az bozan ikinci yöntem olan HPF görüntü kaynaştırma yöntemi izlemektedir. Dalgacık dönüşümü yöntemi ve yeni yöntemin de renk yapısını koruyan diğer yöntemler olduğu görülmektedir. CN, Brovey ve Multiplicative gibi renk tabanlı görüntü kaynaştırma yöntemleri SID ve SAM metriklerinden yüksek değerler

almalarına rağmen bu metriklerin radyometrik bozuklukları tespit etmedeki yetersizliklerinden dolayı başarılı yöntemler olarak kabul edilememektedirler. Ehlers, PCA ve IHS yöntemleri sahip oldukları metrik değerleri doğrultusunda renk yapısını korumayı sağlayamayan yöntemler olarak belirlenmiştir. Ayrıca Tablo 10’da CN, Gram-Schmidt ve HPF yöntemlerinin çok bantlı görüntüdeki konumsal detayları kaynaştırılmış görüntüye aktarmadaki başarıları görülmektedir. CN yöntemi ile elde edilen kaynaştırılmış görüntü Konumsal ERGAS ve Konumsal RMSE metriklerinde sahip olduğu 3,805 ve 50,974 değerleriyle konumsal açıdan en başarılı görüntü olurken bu görüntüyü aynı metriklerden sırasıyla 5,555 ve 74,411 değerlerini alan Gram-Schmidt yöntemi takip etmektedir.

Tablo 13. İkonos çok bantlı görüntüsü ve QBPan görüntüsünün kaynaştırılmasıyla elde edilen kaynaştırılmış görüntülerin metrik değerleri

METRİKLER	RASE %	Spek. RMSE	SID	Spek. ERGAS	SAM	Kon. RMSE	Kon. ERGAS
CN	13,651	154,320	0,003	11,076	0,014	66,198	4,503
GS	12,234	138,302	0,019	10,068	0,081	63,423	4,314
DD	8,858	100,137	0,018	7,282	0,080	129,637	8,818
PCA	22,125	250,120	0,025	18,215	0,121	147,494	10,033
HPF	8,413	95,106	0,018	6,917	0,073	102,657	6,983
EH	60,512	684,082	0,440	49,352	0,608	674,849	45,904
IHS	19,682	163,534	0,118	12,016	0,179	81,648	5,554
KT	7,100	80,266	0,008	5,799	0,000	148,624	10,110
YY	12,945	146,347	0,012	10,573	0,064	45,169	3,073
BR	24,916	281,670	0,010	20,271	0,041	295,673	20,112
MUL	27,623	312,277	0,007	22,507	0,051	273,531	18,606

Tablo 13’ de orijinal İkonos görüntüsü ile QBPan görüntüsünün kaynaştırılmasıyla elde edilen kaynaştırılmış görüntülerin spektral ve konumsal kalitelerinin ölçülmesinde kullanılan birtakım metrik değerleri görülmektedir. Kriter Tabanlı Görüntü Kaynaştırma yöntemi RASE, Spektral RMSE, Spektral ERGAS ve SAM metriklerinde sırasıyla 7,100, 80,266, 5,799 ve 0 değerlerini alarak spektral yapıyı koruyan en iyi yöntem olmuştur. HPF yöntemi ise RASE, Spektral RMSE ve Spektral ERGAS metriklerinden sırasıyla 8,413, 95,106 ve 6,917 değerlerini alarak en iyi ikinci yöntem olmuştur. Gram-Schmidt ve Dalgacık Dönüşümü kaynaştırma yöntemleri ise spektral yapıyı korumada başarılı olan diğer yöntemlerdir. Ehlers, PCA, Brovey ve IHS kaynaştırma yöntemlerinin spektral yapıyı

korumada başarılı olamadıkları görülmektedir. Ehlers yöntemi ile elde edilen kaynaştırılmış görüntünün sınıflandırılması ile elde edilen sınıflandırma sonuçları ile metrik değerler arasındaki tutarsızlıklar gözden kaçmamaktadır. Ehlers kaynaştırılmış görüntüsünün metrik değerleri Ehlers yönteminin spektral yapıyı korumada başarılı olmadığını göstermesine rağmen sınıflandırma sonuçlarının iyi denilebilecek düzeyde olması metriklerin tutarsızlıklarına bir örnektir. Öte yandan Tablo 13’ de Gram-Schmidt, CN, IHS ve HPF kaynaştırma yöntemlerinin konumsal detayları kaynaştırılmış görüntüye aktarmadaki başarıları dikkat çekmektedir.

Görüntü kaynaştırma işleminin başarılı olabilmesi için kaynaştırılmış görüntülerin bantları arasındaki korelasyonların kaynaştırmada kullanılan orijinal çok bantlı görüntünün bantları arasındaki korelasyonlara mümkün olduğunca yakın olmalıdır (Gungor, 2008). Bu sayede çok bantlı görüntünün bantları ile kaynaştırılmış görüntünün bantları arasındaki ilişki korunmuş olur. Ek tablo 1, Ek Tablo 2, Ek Tablo 3 ve Ek Tablo 4’ te uygulama kapsamındaki veri setlerinin kaynaştırılmasıyla elde edilen kaynaştırılmış görüntülerin bantları arasındaki korelasyon değerleri görülmektedir. Bu tablolara göre kaynaştırılmış görüntünün korelasyon değerlerinin orijinal görüntünün korelasyon değerlerine en yakın olmasını sağlayan kaynaştırma yönteminin HPF, Gram-Schmidt ve Kriter Tabanlı Görüntü Kaynaştırma yöntemleri olduğu görülmektedir.

3.1.1. Genel Değerlendirme

3.1 bölümünde kaynaştırılan görüntülerin spektral ve konumsal kalitelerinin kontrolü için birtakım sayısal hesaplamalar gerçekleştirilmiştir. HPF, Dalgacık Dönüşümü ve Kriter Tabanlı Görüntü Kaynaştırma yöntemleri spektral yapıyı korumada başarılı olmuşlardır. Bu kaynaştırma yöntemleri ile kaynaştırılan görüntüler genelde RASE, Spektral RMSE, Spektral ERGAS, SID ve SAM metriklerinden yüksek sonuçlar vermiştir. Aynı zamanda bu kaynaştırma yöntemleri kullanılarak kaynaştırılan görüntülerin orijinal çok bantlı görüntülerle yüksek korelasyona sahip oldukları belirlenmiştir. Bunun yanında bu kaynaştırma yöntemleri kaynaştırmada kullanılan çok bantlı görüntünün bantları arasındaki korelasyon ilişkisini kaynaştırılmış görüntüye aktarmıştır. HPF yöntemi ile kaynaştırılan görüntü kaynaştırma işleminden sonra lineer bir germe işlemine tabi tutulur. Bu germe işlemi kaynaştırılan görüntünün spektral yapısının kaynaştırmada kullanılan çok bantlı görüntüye eşlenmesini sağlar. Kriter Tabanlı Görüntü Kaynaştırma yönteminde ise kriterler

gereği kaynaştırılan görüntünün bantlarının ortalamasının orijinal çok bantlı görüntünün ortalamasına eşit olması sağlanır (Kriter 2). Ayrıca kaynaştırılan görüntünün bantları arasındaki oranlar kaynaştırmada kullanılan çok bantlı görüntünün bantları arasındaki oranlara eşit olur (Kriter 3). Dalgacık Dönüşümü ile görüntü kaynaştırması gerçekleştirilirken Fourier Dönüşümü ile frekans ortamına geçiş yapılarak frekans ortamında filtrelemeler gerçekleştirilir. Frekans ortamından konumsal uzaya geri dönüş yapıldığında spektral yapıda fazla kayıp olmaz. HPF, Dalgacık Dönüşümü ve Kriter Tabanlı Görüntü Kaynaştırma yöntemlerinin bu avantajlarından dolayı bu yöntemler nicel değerlendirmede en başarılı kaynaştırma yöntemleri olarak belirlenmiştir.


Multiplicative, Brovey, IHS, CN ve PCA kaynaştırma yöntemleri nicel değerlendirmede bu veri setleri için en başarısız kaynaştırma yöntemleri olarak belirlenmiştir. Multilicative, Brovey ve CN gibi renk tabanlı yöntemler ile elde edilen kaynaştırılmış görüntülerin bantlarına ait ortalama ve standart sapma değerleri incelendiğinde bu kaynaştırma yöntemlerinin renk yapısında değişikliklere neden oldukları görülmektedir. Bu durum görsel değerlendirme ile de fark edilebilir. Fakat bu yöntemler ile kaynaştırılan görüntüler SAM ve SID metriklerinde oldukça başarılı sonuçlar vermektedirler. Bu iki metrik spektral vektörler arasındaki açıyı ölçmektedir. Görüntü kaynaştırılırken spektral vektörlerin büyüklükleri değişmesine rağmen aralarındaki açı değişmediğinden dolayı bu iki metrik aslında kötü sonuçlar veren CN, Multiplicative ve Brovey kaynaştırma yöntemlerini başarılı olarak göstermektedir. Bu nedenden dolayı bu iki metrik tutarsız sonuçlar vermektedir.

Metriklerin 1.1 bölümünde anlatılan dezavantajlarından dolayı bu çalışmada kaynaştırılmış görüntülerin spektral kalitesi sınıflandırma sonrası doğruluk analizleri yardımıyla irdelenmiştir.

3.2. Görsel Değerlendirme

Bu bölümde çalışma kapsamında kullanılan 4 veri seti ile elde edilen kaynaştırılmış görüntülerin sınıflandırma performansları üzerinde durulmuştur. Her bir kaynaştırılmış görüntü farklı sınıflandırma yöntemleri ile aynı imzalar kullanılarak sınıflandırılmış ve arazideki hangi sınıfların hangi sınıflandırma yöntemleri ile başarılı sınıflandırıldıkları incelenmiştir. Kullanılan sınıflandırma yöntemleri En Yakın Mesafe (EYM), Maksimum Benzerlik (MB), İkili Kodlama (BE), Rastgele Orman (RO), Destek Vektör Makineleri

(DVM) ve Yapay Sinir Ağları (YSA) sınıflandırma yöntemidir. Sınıflandırılmış görüntülerin doğruluk analizleri her bir sınıflandırılmış görüntü için rastgele olarak oluşturulan 450 nokta yardımıyla gerçekleştirilmiştir. Bu bölümdeki sınıflandırılmış görüntüler Destek Vektör Makineleri sınıflandırıcısı ile elde edilen görüntülerdir. Bunun nedeni bu çalışma kapsamındaki veri setlerinin sınıflandırılmasında en başarılı sınıflandırma yöntemi olarak Destek Vektör Makinelerinin sınıflandırıcısının belirlenmesidir. Ayrıca bu bölümde gösterilen örnek görüntülerin hepsi kırmızı-yeşil-mavi bant kombinasyonlarında görüntülenmiştir.




Şekil 18. Orijinal Worldview-2 görüntüsünün pankromatik bandıyla kaynaştırılmasıyla üretilen kaynaştırılmış görüntülerin sınıflandırma doğrulukları

Sürmene bölgesine ait Worldview-2 ve aynı uyduya ait pankromatik görüntünün çalışma kapsamındaki kaynaştırma yöntemleriyle kaynaştırılması sonucu üretilen kaynaştırılmış görüntülerin genel sınıflandırma doğrulukları Şekil 18’ de gösterilmiştir. Bu değerlere göre Destek Vektör Makineleri sınıflandırıcısı % 69,3 ortalama sınıflandırma doğruluğu ile en iyi sınıflandırma yöntemi olurken Rastgele Orman sınıflandırıcısı % 68 genel ortalama ile en iyi ikinci sınıflandırma yöntemi olmuştur. Bu yöntemleri % 66,9 genel ortalama ile en iyi ikinci sınıflandırma yöntemi olmuştur. Bu yöntemleri % 66,9 genel ortalama ile Yapay Sinir Ağları ve % 65,3 ile Maksimum Benzerlik yöntemi takip etmektedir. En Yakın Mesafe yöntemi ve İkili Kodlama yöntemleri % 41,4 ile en kötü

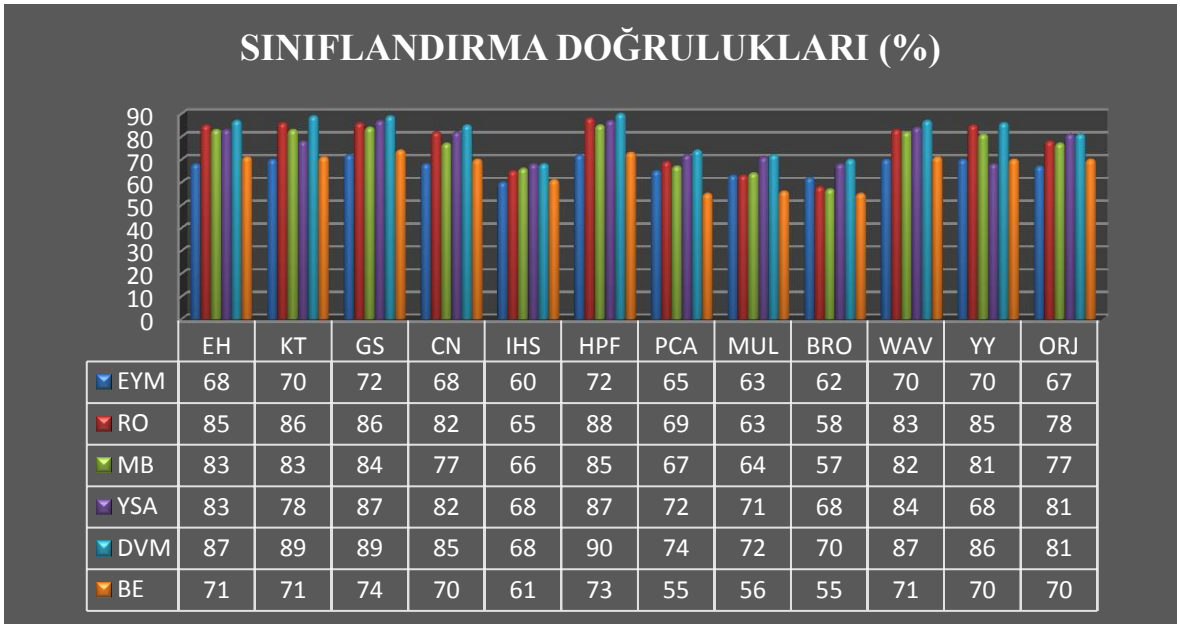
sınıflandırma yöntemi olmuşlardır. Orijinal görüntünün tüm yöntemlerle sınıflandırılmasında ortalama % 60 sınıflandırma doğruluğuna ulaşılmıştır. Kaynaştırılmış görüntülerin tüm sınıflandırma yöntemlerindeki ortalama sınıflandırma doğrulukları incelendiğinde en yüksek ortalama sınıflandırma doğruluğuna % 67,8 ile HPF ile kaynaştırılmış görüntünün sınıflandırılması ile ulaşılmıştır. Bunu % 67,2 ile Yeni Yöntem ve % 64,2 ile Ehlers Görüntü Kaynaştırma yöntemi ile kaynaştırılmış görüntü takip etmektedir. En kötü sınıflandırma performanslarını ise ortalama % 45,2 ve % 48,5 ile sırasıyla IHS ve PCA yöntemlerinin gösterdikleri belirlenmiştir. Yine Sürmene bölgesine ait Landsat ETM+ veri setlerinin kaynaştırılmasıyla elde edilen görüntülerin bu uygulama kapsamındaki sınıflandırma yöntemleri ile sınıflandırıldıklarında elde edilen genel sınıflandırma doğrulukları Şekil 19’ da görülmektedir. HPF yöntemi ile elde edilen kaynaştırılmış görüntü bütün sınıflandırma yöntemleri ile sınıflandırıldığında ortalama % 86 genel doğruluğa ulaşılmıştır. Bu oran HPF yönteminin spektral yapıyı korumadaki başarısını göstermektedir. HPF yöntemini % 84 genel doğrulukla Kriter Tabanlı Görüntü Kaynaştırma yöntemi takip etmektedir. Literatüre katılan yeni yöntem ise ortalama % 83 genel doğrulukla üçüncü sırada yer almaktadır. Sınıflandırma yöntemlerinden elde edilen sonuçlar incelendiğinde Destek Vektör Makineleri sınıflandırma yönteminin % 89 genel ortalama ile en başarılı sınıflandırma yöntemi olduğu belirlenmiştir. Yapay Sinir Ağları sınıflandırma yöntemi ise % 87 ortalama genel sınıflandırma doğruluğu ile en başarılı ikinci sınıflandırma yöntemi olurken Rastgele Orman sınıflandırma yöntemi % 85 genel doğrulukla üçüncü en iyi sınıflandırma yöntemi olmuştur.

Şekil 20’ de Ikonos veri setlerinin kaynaştırılmasıyla elde edilen kaynaştırılmış görüntülerinin bu uygulama kapsamındaki genel sınıflandırma doğrulukları görülmektedir. Bu sonuçlar incelendiğinde HPF kaynaştırma yöntemi ile elde edilen kaynaştırılmış görüntüler sınıflandırıldığında ortalama % 82,5 genel sınıflandırma doğruluğuna ulaşılmıştır. Gram-Schmidt kaynaştırma yöntemi ile elde edilen kaynaştırılmış görüntünün sınıflandırılması ile ortalama % 82 genel doğruluğa ulaşılrken Ehlers, Dalgacık Dönüşümü ve Kriter Tabanlı Görüntü Kaynaştırma yöntemleri ile elde edilen kaynaştırılmış görüntülerin tüm sınıflandırma yöntemleri ile sınıflandırılması ile % 79,5 ortalama genel sınıflandırma doğruluğuna ulaşılmıştır. Destek Vektör Makineleri sınıflandırıcısı en başarılı sınıflandırma sonuçlarını vermiştir. Destek Vektör Makineleri sınıflandırıcısı kullanılarak sınıflandırılan kaynaştırılmış görüntülerde % 81,5 ortalama genel doğruluk elde edilmiştir. Destek Vektör Makinelerini % 77,4 ortalama genel

sınıflandırma doğruluğu veren Yapay Sinir Ağları sınıflandırıcı takip etmektedir. En yüksek üçüncü ortalama genel sınıflandırma doğruluğunu veren sınıflandırma yöntemi ise Rastgele Orman sınıflandırma yöntemidir.




Şekil 19. Orijinal Landsat ETM+ görüntüsünün pankromatik bandıyla kaynaştırılmasıyla üretilen kaynaştırılmış görüntülerin sınıflandırma doğrulukları




Şekil 20. Orijinal Ikonos görüntüsünün pankromatik bandıyla kaynaştırılmasıyla üretilen kaynaştırılmış görüntülerin sınıflandırma doğrulukları

Şekil 21’ de İkonos ve QBPan görüntülerinin kaynaştırılması ile elde edilen kaynaştırılmış görüntülerin bu uygulama kapsamındaki sınıflandırma yöntemleri ile sınıflandırılmasıyla elde edilen genel sınıflandırma sonuçları gösterilmiştir. Bu sonuçlara göre HPF kaynaştırma yöntemi ile elde edilen kaynaştırılmış görüntü % 82 ortalama genel sınıflandırma doğruluğu ile en yüksek sınıflandırma sonuçlarını verirken, Gram-Schmidt kaynaştırma yöntemi ile elde edilen kaynaştırılmış görüntü % 80 ortalama genel sınıflandırma doğruluğu ile ikinci en yüksek sınıflandırma doğruluğunu göstermiştir. En yüksek üçüncü sınıflandırma doğruluğunu ise % 79 ortalama genel sınıflandırma doğruluğu ile Kriter Tabanlı Görüntü Kaynaştırma yöntemi vermiştir. Kaynaştırılmış görüntüler Destek Vektör Makineleri ile sınıflandırıldıklarında ortalama % 77 sınıflandırma doğruluğuna ulaşılmıştır, aynı zamanda bu oran en yüksek ortalama genel sınıflandırma doğruluğudur. Kaynaştırılmış görüntülerin Rastgele Orman sınıflandırıcısı ile sınıflandırılması ile ise en yüksek ikinci ortalama genel sınıflandırma doğruluğuna ulaşılmıştır (% 76). Yapay Sinir Ağları sınıflandırıcısı ise % 75 ortalama genel sınıflandırma doğruluğu ile en yüksek sınıflandırma sonucunu veren üçüncü sınıflandırıcı olabilmıştır.



Şekil 21. Orijinal İkonos ve QBPan görüntülerinin kaynaştırılmasıyla üretilen kaynaştırılmış görüntülerin sınıflandırma doğrulukları


3.2.1. IHS Kaynaştırması




Şekil 22. Orjinal görüntü ve IHS kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Worldview-2 MS – Worldview-2 Pan)

Worldview-2 veri setlerinin kaynaştırılmasıyla elde edilen kaynaştırılmış görüntülerin sınıflandırma performansları Şekil 22’ de gösterilmiştir. IHS yöntemi ile kaynaştırılan görüntü görsel olarak incelendiğinde kaynaştırılmış görüntüdeki yeşil alanların ve gölgelik alanların orijinal görüntüye oranla daha maviye yakın olduğu görülmektedir. Bu sonuçlardan da anlaşılacağı üzere kaynaştırılmış görüntüde en yüksek genel sınıflandırma doğruluğunu veren sınıflandırıcı Destek Vektörleri sınıflandırıcısıdır. Aynı zamanda, yine bu sonuçlara göre IHS yöntemi ile kaynaştırılmış görüntünün sınıflandırma doğruluğunun orijinal görüntüye göre daha düşük olduğu görülmektedir. Bu durum da bu kaynaştırma yönteminin sınıflandırma performansına olumsuz etki ettiğini göstermektedir. IHS yöntemi ile görüntü kaynaştırılırken sadece üç bant kullanılması sınıflandırma performansını düşüren başlıca etkidir. Çünkü kullanılmayan diğer bantların etkileri kaynaştırılmış görüntüde bulunmamaktadır. IHS kaynaştırılmış görüntüsü Destek Vektör makineleri ile sınıflandırıldığında çay, fındık ve orman alanları için sınıflandırma doğrulukları sırasıyla % 52, % 42 ve % 51 iken, Maksimum Benzerlik sınıflandırıcısında % 35, % 51 ve % 39, Yapay Sinir Ağları sınıflandırıcısında % 56, % 50 ve % 53, İkili Kodlama sınıflandırıcısında % 0, % 0 ve % 0, En Yakın Mesafe sınıflandırıcısında % 17, % 33 ve % 34, Rastgele Orman sınıflandırıcısında ise % 43, % 40 ve % 51 olduğu belirlenmiştir. Görüldüğü üzere bu üç sınıflı birbirinden ayırmada en başarılı yöntem Yapay Sinir Ağları Sınıflandırıcısıdır. Kaynaştırılmış görüntüde bazı açık renkli bina çatıları ile yol sınıfının karıştığı gözlenmektedir. Ayrıca orijinal görüntü sınıflandırıldığında su sınıfı diğer sınıflardan başarılı bir şekilde ayrılırken kaynaştırılmış görüntülerde yer yer diğer

sınıflara karıştığı gözlenmiştir. Genel olarak bu kaynaştırma yönteminin sınıflandırma performansını düşürdüğü söylenebilir.




Şekil 23. Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), IHS kaynaştırılmış görüntüsü (c), IHS kaynaştırılmış görüntüsünün sınıflandırılması (d) (Worldview-2 MS – Worldview-2 Pan)



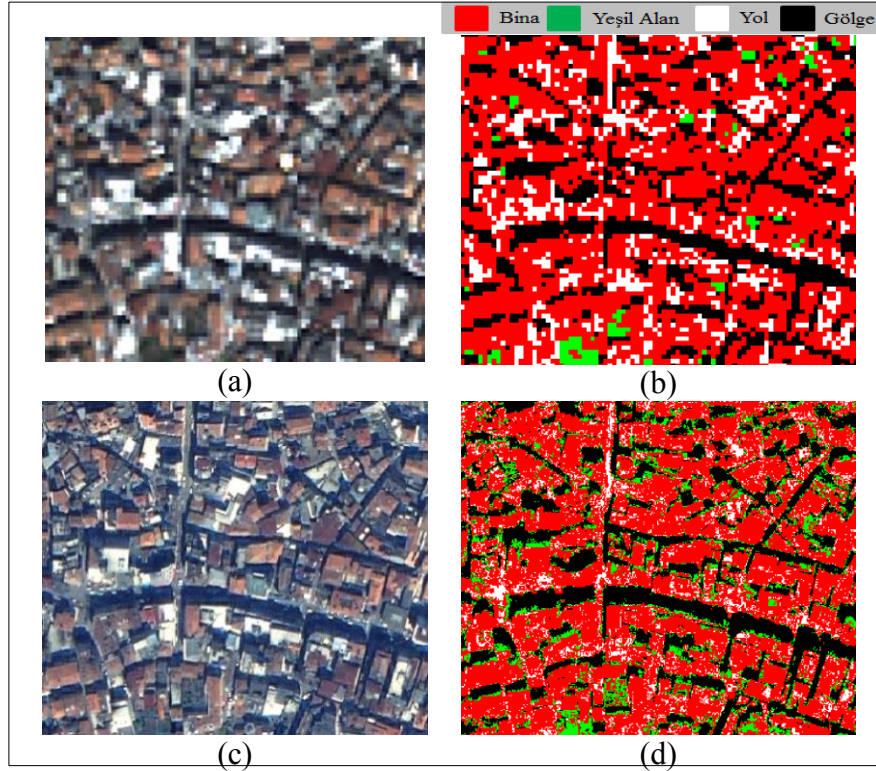
Şekil 24. Orijinal görüntü ve IHS kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Landsat ETM+ MS – Landsat ETM+ Pan)

Landsat ETM+ veri setinin IHS yöntemiyle kaynaştırılmasıyla elde edilen kaynaştırılmış görüntünün sınıflandırma yöntemleriyle sınıflandırılmasıyla elde edilen genel sınıflandırma doğrulukları Şekil 24’ de görülmektedir. Sınıflandırılmış görüntüler incelendiğinde bütün sınıflandırılmış görüntülerde tüm sınıfların birbirlerine karıştıkları belirlenmiştir. Kent sınıfı en yüksek sınıflandırma doğruluğunu % 90 ile Destek Vektör Makineleri sınıflandırıcısında gösterirken orman sınıfı en yüksek sınıflandırma doğruluğunu % 83 ile Maksimum Benzerlik sınıflandırıcısında göstermiştir. Toprak ve su sınıfları için ise en yüksek sınıflandırma doğruluklarına sırasıyla % 90 ve % 83 doğruluklarla Yapay Sinir Ağları sınıflandırma yöntemleriyle ulaşılmıştır. Şekil 24’ de de görüldüğü üzere IHS kaynaştırma yöntemi sınıflandırma performansını düşürmektedir.




Şekil 25. Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), IHS kaynaştırılmış görüntüsü (c), IHS kaynaştırılmış görüntüsünün sınıflandırılması (d) (Landsat ETM+ MS – Landsat ETM+ Pan)

İkonos veri setinin IHS kaynaştırma yöntemiyle kaynaştırılmasıyla elde edilen kaynaştırılmış görüntünün bu uygulama kapsamındaki sınıflandırma yöntemleriyle sınıflandırılmasıyla elde edilen genel sınıflandırma doğrulukları Şekil 27’ de görülmektedir. Bu kaynaştırma yönteminin çok bantlı görüntüdeki konumsal detayların kaynaştırılmış görüntüye aktarılmasında oldukça başarılı olduğu görülmektedir. Şekil 27 bu kaynaştırma yönteminin sınıflandırma doğruluğunu düşüren bir yöntem olduğunu göstermektedir. IHS kaynaştırılmış görüntüsü sınıflandırıldığında görüntüdeki yeşil alanların diğer sınıflara fazla oranda karıştıkları görülmektedir. Yol sınıfı da tıpkı yeşil alan sınıfında olduğu gibi diğer sınıflara karışmaktadır. Gölge, yeşil alan ve yol sınıfları sırasıyla % 83, % 63 ve % 77 doğrulukla Destek Vektör Makineleri sınıflandırıcısında en iyi sınıflandırılırken bina sınıfı % 71 doğrulukla en iyi Yapay Sinir Ağları sınıflandırıcısında sınıflandırılmıştır.

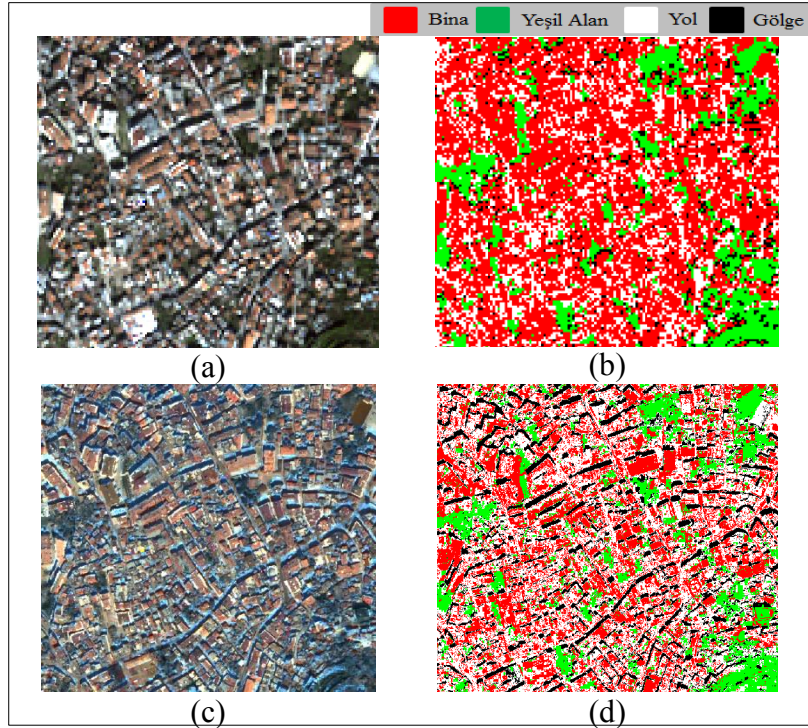


Şekil 26. Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), IHS kaynaştırılmış görüntüsü (c), IHS kaynaştırılmış görüntüsünün sınıflandırılması (d) (İkonos MS – İkonos Pan)




Şekil 27. Orjinal görüntü ve IHS kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Ikonos MS – Ikonos Pan)

Ikonos çok bantlı görüntüsü ile QBPan görüntüsünün IHS yöntemiyle kaynaştırılmasıyla elde edilen kaynaştırılmış görüntünün sınıflandırma performansı Şekil 29' da görülmektedir. Sınıflandırma sonuçlarına göre yeşil alan ve yol sınıflarını diğer sınıflardan ayıran en iyi yöntem sırasıyla % 76 ve % 78 doğruluklarla İkili Kodlama sınıflandırma yöntemi olurken bina sınıfını en iyi ayıran yöntem % 68 ile Yapay Sinir Ağları, gölge sınıfını en iyi sınıflandıran yöntem % 68 ile En Yakın Mesafe sınıflandırma yöntemi olmuştur.




Şekil 28. Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), IHS kaynaştırılmış görüntüsü (c), IHS kaynaştırılmış görüntüsünün sınıflandırılması (d) (Ikonos MS – QBPan)




Şekil 29. Orijinal görüntü ve IHS kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (İkonos MS – QBPan)

3.2.2. Brovey Kaynaştırması

Worldview-2 veri setinin Brovey kaynaştırma yöntemiyle kaynaştırılmasıyla elde edilen kaynaştırılmış görüntünün bu uygulama kapsamındaki sınıflandırma yöntemleriyle sınıflandırılmasıyla elde edilen genel sınıflandırma doğrulukları Şekil 30’ da görülmektedir. Brovey yöntemiyle kaynaştırılmış görüntüde su ve yeşil alanlardaki renklerin orijinal görüntüye göre daha açık tonlarda olduğu görülmektedir. Çay sınıfının En Yakın Mesafe ve İkili Kodlama yöntemleri kullanılarak gerçekleştirilen sınıflandırmalarda fındık ve orman sınıflarına daha fazla karıştığı gözlemlenmiştir. Brovey kaynaştırılmış görüntüsü Destek Vektör Makineleri ile sınıflandırıldığında çay, fındık ve orman alanları için sınıflandırma doğrulukları sırasıyla % 50, % 43 ve % 55 iken, Maksimum Benzerlik sınıflandırıcısında % 35, % 57 ve % 48, Yapay Sinir Ağları sınıflandırıcısında % 37, % 52 ve % 65, İkili Kodlama sınıflandırıcısında % 27, % 36 ve % 48, En Yakın Mesafe sınıflandırıcısında % 31, % 38 ve % 36, Rastgele Orman sınıflandırıcısında ise % 68, % 47 ve % 50 olmaktadır. Bu sonuçlara göre bu üç sınıfı birbirinden en iyi ayıran yöntem Rastgele Orman Sınıflandırıcısıdır. Toprak ve kayalık sınıflarının görüntü kaynaştırma sonrasında yol ve bina sınıflarına karıştığı gözlenmiştir. Toprak ve bina sınıflarını ayırmada en başarılı yöntem Destek Vektör Makineleri sınıflandırıcısıdır. Bu iki sınıfın bu yöntemle sınıflandırılması sonucunda sırasıyla % 75 ve % 70 doğruluk sağlanmıştır. Kayalık sınıfını en iyi ayıran yöntem ise % 83 ile Rastgele Orman sınıflandırıcısı olup yol sınıfını en iyi ayıran yöntem ise % 58 ile Yapay Sinir Ağları sınıflandırıcısıdır. Tüm sınıflandırma yöntemleri içerisinde içinde en kötü sınıflandırma doğruluklarını En Yakın Mesafe ve İkili Kodlama yöntemleri vermektedir.




Şekil 30. Orjinal görüntü ve IHS kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Worldview-2 MS – Worldview-2 Pan)




Şekil 31. Orjinal görüntü (a), Orjinal görüntünün sınıflandırılması (b), Bovey kaynaştırılmış görüntüsü (c), Bovey kaynaştırılmış görüntüsünün sınıflandırılması (d) (Worldview-2 MS – Worldview-2 Pan)

Landsat ETM+ veri setinin Bovey kaynaştırma yöntemiyle kaynaştırılmasıyla elde edilen kaynaştırılmış görüntünün bu uygulama kapsamındaki sınıflandırma yöntemleriyle sınıflandırılmasıyla elde edilen genel sınıflandırma doğrulukları Şekil 33' de

görülmektedir. Bu sonuçlardan da görüldüğü üzere Brovey yöntemi görüntü kaynaştırma esnasında renk yapısını bozan bir yöntemdir. Bu yöntemin sınıflandırma performansını azalttığı Şekil 29' da görülmektedir. Brovey yöntemi ile elde edilen kaynaştırılmış görüntüler Destek Vektör Makineleri ve En Yakın Mesafe yöntemleriyle sınıflandırıldığında su sınıfının yer yer diğer sınıflara karıştığı gözlemlenmiştir. Toprak sınıfı ise İkili Kodlama sınıflandırma yöntemi ile sınıflandırılan görüntüde orman ve kent sınıfları ile karışma göstermektedir. Kent ve orman sınıfları Destek Vektör Makineleri sınıflandırıcısında en fazla başarı ile (% 97 ve % 87) diğer sınıflardan ayrılabilirken, toprak sınıfı % 93 başarı ile Yapay Sinir Ağları sınıflandırıcısında, su sınıfı ise % 90 başarı ile Rastgele Orman sınıflandırıcısında sınıflandırılmıştır.




Şekil 32. Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Brovey kaynaştırılmış görüntüsü (c), Brovey kaynaştırılmış görüntüsünün sınıflandırılması (d) (Landsat ETM+ MS – Landsat ETM+ Pan)




Şekil 33. Orjinal görüntü ve Brovey kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Landsat ETM+ MS – Landsat ETM+ Pan)


İkonos ve aynı uyduya ait pankromatik görüntünün Brovey yöntemine göre kaynaştırılmasıyla elde edilen kaynaştırılmış görüntünün bu uygulama kapsamındaki sınıflandırma yöntemleriyle sınıflandırılmasıyla elde edilen genel sınıflandırma doğrulukları Şekil 34’ de görülmektedir. Bu kaynaştırılmış görüntü İkili Kodlama sınıflandırıcısı ile sınıflandırıldığında yol sınıfının oldukça fazla oranda diğer sınıflara karıştığı görülmektedir. Gölge ve yeşil alan sınıfları genelde yüksek doğrulukta sınıflandırılabilmiştir. Farklı renkli bina çatıları bina sınıfının diğer sınıflara karışmasını sağlamıştır. Gölge sınıfını en iyi ayıran yöntem % 90 doğrulukla Maksimum Benzerlik sınıflandırma yöntemi iken, bina sınıfını en iyi ayıran yöntem % 68 ile Destek Vektör Makineleri, yeşil alan sınıfını en iyi ayıran yöntem % 80 ile Rastgele Orman yöntemi ve yol sınıfını en iyi ayıran yöntem ise % 66 ile Yapay Sinir Ağları yöntemidir.



Şekil 34. Orjinal görüntü ve Brovey kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (İkonos MS – İkonos Pan)




Şekil 35. Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Brovey kaynaştırılmış görüntüsü (c), Brovey kaynaştırılmış görüntüsünün sınıflandırılması (d) (Ikonos MS – Ikonos Pan)



Şekil 36. Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Brovey kaynaştırılmış görüntüsü (c), Brovey kaynaştırılmış görüntüsünün sınıflandırılması (d) (Ikonos MS – QBPan)

Brovey kaynaştırma yöntemi aynı sensörden alınan görüntülerde olduğu gibi farklı sensörlerden alınan görüntüleri kaynaştırırken çok bantlı görüntünün renk yapısında değişikliklere neden olmaktadır. Dolayısıyla bu yöntem genel sınıflandırma performansına olumsuz etki etmektedir. Brovey yöntemiyle kaynaştırılan İkonos çok bantlı görüntüsü ve QBPan görüntüsü uygulama kapsamındaki sınıflandırma yöntemleriyle sınıflandırıldığında elde edilen genel sınıflandırma doğrulukları Şekil 37’ de gösterilmiştir. Yeşil alan ve gölge sınıflarını en iyi sınıflandıran sınıflandırıcı % 80’ lik doğrulukla Destek Vektör Makineleri sınıflandırıcısı olurken bina sınıfını en iyi sınıflandıran sınıflandırıcısı % 66 ile Rasgele Orman sınıflandırıcısı, yol sınıfını en iyi sınıflandıran sınıflandırıcı ise % 80 ile Yapay Sinir Ağları sınıflandırıcısı olmuştur.




Şekil 37. Orijinal görüntü ve Brovey kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (İkonos MS – QBPan)


3.2.3. Ehlers Kaynaştırması

Ehlers yöntemi görüntünün spektral yapısını korumakta başarılı denilebilecek bir yöntemdir. Worldview-2 ve aynı uyduya ait pankromatik görüntünün Ehlers yöntemine göre kaynaştırılmasıyla elde edilen kaynaştırılmış görüntünün bu uygulama kapsamındaki sınıflandırma yöntemleriyle sınıflandırılmasıyla elde edilen genel sınıflandırma doğrulukları Şekil 39’ da görülmektedir. Yol, bina ve gölge sınıfları orijinal görüntünün sınıflandırılmasında birbirlerine fazla karışmazken bu karışma oranının kaynaştırılmış görüntünün sınıflandırılması ile elde edilen tematik görüntüde arttığı görülmektedir. Aynı zamanda bazı bölgelerde yol sınıfı ile su sınıfının karıştığı görülmektedir. Fındık ve orman sınıfı en yüksek sınıflandırma doğruluğunu sırasıyla % 68 ve % 81 doğrulukta Destek Vektör Makineleri sınıflandırıcısında göstermiştir. Çay sınıfı ise % 76 ile en iyi Rastgele Orman sınıflandırıcısında sınıflandırılmıştır. Bina sınıfı en iyi % 93 ile Rastgele Orman

Sınıflandırıcısında, kayalık sınıfı ise % 96 ile en iyi Yapay Sinir Ağları Sınıflandırıcısında sınıflandırılmıştır. Yol sınıfı ise en fazla sınıflandırma doğruluğunu % 71 ile Destek Vektör Makineleri sınıflandırıcısında göstermiştir. Bu yöntem bu verinin sınıflandırma performansına olumlu etki yapmıştır.




Şekil 38. Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Ehlers kaynaştırılmış görüntüsü (c), Ehlers kaynaştırılmış görüntüsünün sınıflandırılması (d) (Worldview-2 MS – Worldview-2 Pan)




Şekil 39. Orijinal görüntü ve Ehlers kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Worldview-2 MS – Worldview-2 Pan)

Landsat ETM+ veri setinin Ehlers kaynaştırma yöntemiyle kaynaştırılmasıyla elde edilen kaynaştırılmış görüntünün bu uygulama kapsamındaki sınıflandırma yöntemleriyle sınıflandırılmasıyla elde edilen genel sınıflandırma doğrulukları Şekil 41’ de görülmektedir. Bu kaynaştırma yöntemi Destek Vektör Makineleri, Yapay Sinir Ağları, Maksimum Benzerlik, İkili Kodlama ve En Yakın Mesafe sınıflandırma yöntemlerinin doğruluklarını artırırken, Rastgele Orman sınıflandırıcısının doğruluğunu azaltmıştır. Bu durum Şekil 41’ de görülmektedir. Destek Vektör Makineleri ile Ehlers kaynaştırılmış görüntüsü sınıflandırıldığında su sınıfı ile kent sınıfının karıştığı, Rastgele Orman sınıflandırıcısı ile sınıflandırıldığında su sınıfı ile orman sınıfının karıştığı görülmektedir. Toprak ve kent sınıfı en yüksek başarı ile (% 93 ve % 97) Yapay Sinir Ağları sınıflandırıcısında, su ve orman sınıfı ise en yüksek başarı ile (% 96 ve % 93) Destek Vektör Makineleri sınıflandırıcısında sınıflandırılmıştır.




Şekil 40. Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Ehlers kaynaştırılmış görüntüsü (c), Ehlers kaynaştırılmış görüntüsünün sınıflandırılması (d) (Landsat ETM+ MS – Landsat ETM+ Pan)




Şekil 41. Orjinal görüntü ve Ehlers kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Landsat ETM+ MS – Landsat ETM+ Pan)

Ehlers kaynaştırma yöntemiyle Ikonos veri setinden elde edilen kaynaştırılmış görüntünün bu uygulama kapsamındaki sınıflandırma yöntemleriyle sınıflandırılmasıyla elde edilen genel sınıflandırma doğrulukları Şekil 42’ de görülmektedir. Destek Vektör Makineleri sınıflandırıcısı ile elde edilen sınıflandırılmış görüntüde yol ve bina sınıfları birbirlerine az miktarda karışırken bu durum diğer sınıflandırma yöntemleri ile elde edilen sınıflandırılmış görüntülerde tam tersidir. Kaynaştırılmış görüntü Destek Vektör Makineleri ve Maksimum Benzerlik yöntemleri ile sınıflandırıldığında yeşil alan sınıfı diğer sınıflara az da olsa karışmaktadır. Diğer sınıflandırma yöntemleri ile elde edilen görüntülerde ise karışma daha fazla olmaktadır. Gölge sınıfı en iyi Rastgele Orman, Maksimum Benzerlik ve Destek Vektör Makineleri sınıflandırıcılarında % 93 doğrulukla sınıflandırılmıştır. Bina ve yeşil alan sınıfları sırasıyla % 89 ve % 90 doğruluklarla en iyi Destek Vektör Makineleri sınıflandırıcısında sınıflandırılırken yol sınıfı % 81 doğrulukla en iyi Maksimum Benzerlik sınıflandırıcısında sınıflandırılmıştır.




Şekil 42. Orjinal görüntü ve Ehlers kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Ikonos MS – Ikonos Pan)




Şekil 43. Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Ehlers kaynaştırılmış görüntüsü (c), Ehlers kaynaştırılmış görüntüsünün sınıflandırılması (d) (Ikonos MS – Ikonos Pan)

Ikonos çok bantlı görüntüsü ve QBPan görüntüsünün Ehlers yöntemiyle kaynaştırılmasıyla üretilen kaynaştırılmış görüntünün sınıflandırma performansları Şekil 44’ de gösterilmiştir. Destek Vektör Makineleri sınıflandırıcısı bina ve gölge sınıflarını sırasıyla % 81 ve % 87 doğruluklarla en iyi sınıflandırırken yeşil alan ve yol sınıflarını en iyi sınıflandıran sınıflandırıcı % 82 ve % 86 doğruluklarla Rastgele Orman sınıflandırıcısı olmuştur. Şekil 59’ da görüldüğü üzere bu yöntem sınıflandırma performansına olumlu yönde etki etmektedir.



Şekil 44. Orijinal görüntü ve Ehlers kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Ikonos MS – QBPan)




Şekil 45. Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Ehlers kaynaştırılmış görüntüsü (c), Ehlers kaynaştırılmış görüntüsünün sınıflandırılması (d) (Ikonos MS – QBPan)


3.2.4. HPF Kaynaştırması

Worldview-2 ve aynı uyduya ait pankromatik görüntünün HPF kaynaştırma yöntemiyle kaynaştırılmasıyla elde edilen kaynaştırılmış görüntüde ilk dikkat çeken görüntüdeki konumsal detayların kalitesidir. Kaynaştırılmış görüntü uygulama kapsamındaki sınıflandırma yöntemlerine göre aynı imzalar kullanılarak sınıflandırıldığında elde edilen sınıflandırma doğrulukları Şekil 47’ de gösterilmiştir. Bu sonuçlar bu kaynaştırma yönteminin sınıflandırma performansını arttırdığını işaret etmektedir. HPF yöntemi ile kaynaştırılmış görüntü Destek Vektör Makineleri sınıflandırıcısı ile sınıflandırıldığında % 78’ lik genel doğruluk elde edilmektedir. Bu oran bu çalışmada Worldview-2 veri setinden üretilen kaynaştırılmış görüntüler arasındaki en yüksek sınıflandırma doğruluğudur. Kaynaştırılmış görüntü sınıflandırıldığında çay sınıfını en iyi ayıran sınıflandırıcının % 82’ lik oranla Destek Vektör Makineleri sınıflandırıcısı olduğu belirlenmiştir. Fındık sınıfını en iyi ayıran yöntem % 71 ile Maksimum Benzerlik yöntemi olurken orman sınıfını en iyi ayıran sınıflandırıcı ise % 81 ile Yapay Sinir Ağları

sınıflandırıcısı olmuştur. En Yakın Mesafe ve İkili Kodlama sınıflandırma yöntemleri fındık, çay ve orman sınıflarının birbirlerinden ayrılmasında başarısız olmuşlardır. Yol sınıfı en iyi Destek Vektör makineleri sınıflandırıcısında sınıflandırılırken (% 71), en kötü En Yakın Mesafe (% 49) sınıflandırıcısında sınıflandırılmıştır. Su ve yol sınıflarının sınıflandırılmış görüntülerde az da olsa birbirlerine karışığı gözlemlenmiştir. Bina ve toprak sınıfları ise Destek Vektör Makineleri ve Yapay Sinir Ağları sınıflandırıcılarında diğer sınıflardan daha başarılı bir şekilde ayrıldıkları görülmektedir. Gölge sınıfı En Kısa Mesafe yöntemi ile sınıflandırıldığında su sınıfı ile karışmaktadır. Bu görüntü en kötü sınıflandırma performansını En Yakın Mesafe sınıflandırıcısı ile göstermektedir. Bu yöntem ile kaynaştırılan görüntü sınıflandırıldığında deniz sınıfı hariç diğer bütün sınıfların birbirleri ile karıştığı görülmektedir. HPF yöntemi ile kaynaştırılan görüntü sınıflandırma sonuçları itibariyle sınıflandırma performansını bu veri seti için en fazla arttıran yöntemdir.




Şekil 46. Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), HPF kaynaştırılmış görüntüsü (c), HPF kaynaştırılmış görüntüsünün sınıflandırılması (d) (Worldview-2 MS – Worldview-2 Pan)




Şekil 47. Orjinal görüntü ve HPF kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Worldview-2 MS – Worldview-2 Pan)

Landsat ETM+ veri setinin HPF kaynaştırma yöntemiyle kaynaştırılmasıyla elde edilen görüntü bu uygulama kapsamındaki sınıflandırma yöntemleriyle sınıflandırıldığında elde edilen genel sınıflandırma doğrulukları Şekil 48’ de gösterilmiştir. Bu yöntemin sınıflandırma performansına olumlu yönde etki ettiği Şekil 48’ de görülmektedir. Destek Vektör Makineleri ve Yapay Sinir Ağları sınıflandırma yöntemleri su sınıfı ile kent sınıfının ayrılabilmesini kolaylaştırırken diğer sınıflandırma yöntemlerinde bu durum görülmemektedir. Sınıflandırma sonuçları incelendiğinde En Yakın Mesafe ve İkili Kodlama sınıflandırıcılarının diğer yöntemlere göre daha az başarılı oldukları belirlenmiştir. Bu sınıflandırıcılarla elde edilen sınıflandırılmış görüntülerde bütün sınıfların birbirleri ile fazla oranda karıştığı görülmektedir. Toprak ve kent sınıfları Destek Vektör Makineleri sınıflandırıcısında en yüksek sınıflandırma doğruluklarını (% 93 ve % 97) gösterirken, su ve orman sınıfları en yüksek sınıflandırma doğruluklarını (% 96 ve % 95) Yapay Sinir Ağları yöntemlerinde göstermektedir.




Şekil 48. Orjinal görüntü ve HPF kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Landsat ETM+ MS – Landsat ETM+ Pan)




Şekil 49. Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), HPF kaynaştırılmış görüntüsü (c), HPF kaynaştırılmış görüntüsünün sınıflandırılması (d) (Landsat ETM+ MS – Landsat ETM+ Pan)

HPF kaynaştırma yöntemi kullanılarak Ikonos ve kendi pankromatik bandından elde edilen kaynaştırılmış görüntü bu uygulama kapsamındaki sınıflandırma yöntemleriyle sınıflandırıldığında ulaşılan genel sınıflandırma doğrulukları Şekil 51’ de gösterilmiştir. Özellikle Destek Vektör Makineleri, Yapay Sinir Ağları ve Rastgele Orman sınıflandırıcıları bu kaynaştırma yönteminin sınıflandırma performansına oldukça olumlu ettiğini göstermektedir. Yeşil alan ve yol sınıfları sırasıyla % 93 ve % 83 doğruluklarla en iyi Yapay Sinir Ağları ve Destek Vektör Makineleri sınıflandırıcılarında sınıflandırılırken gölge sınıfı % 94 doğrulukla Destek Vektör Makineleri sınıflandırıcısında ve bina sınıfı % 90 doğrulukla en iyi Rastgele Orman sınıflandırıcısında sınıflandırılmıştır.




Şekil 50. Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), HPF kaynaştırılmış görüntüsü (c), HPF kaynaştırılmış görüntüsünün sınıflandırılması (d) (Ikonos MS – Ikonos Pan)




Şekil 51. Orijinal görüntü ve HPF kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Ikonos MS – Ikonos Pan)

İkonos ve QBPan görüntülerinin HPF yöntemiyle kaynaştırılmasıyla elde edilen kaynaştırılmış görüntünün bu çalışma kapsamındaki sınıflandırma yöntemleriyle sınıflandırılmasıyla elde edilen genel sınıflandırma doğrulukları Şekil 52’ de gösterilmiştir. Destek Vektör Makineleri sınıflandırıcısı bina ve gölge sınıflarının sınıflandırılmasında en yüksek sınıflandırma doğruluklarını göstermiştir (sırasıyla % 87 ve % 92). Rastgele Orman sınıflandırıcısı % 96 doğrulukla yeşil alan sınıfını sınıflandırabilirken, Yapay Sinir Ağları sınıflandırıcısı yol sınıfını % 91 doğrulukla sınıflandırabilmiştir.




Şekil 52. Orijinal görüntü ve HPF kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (İkonos MS – QBPan)




Şekil 53. Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), HPF kaynaştırılmış görüntüsü (c), HPF kaynaştırılmış görüntüsünün sınıflandırılması (d) (İkonos MS – QBPan)

3.2.5. Multiplicative Kaynaştırması

Worldview-2 veri setinin Multiplicative yöntemi ile kaynaştırılmasıyla üretilen kaynaştırılmış görüntü incelendiğinde görüntüdeki bütün sınıfların renklerinin orijinal görüntüye oranla oldukça değiştiği görülmektedir. Brovey yöntemi gibi bu yöntem de görüntünün spektral yapısında değişikliklere neden olmaktadır. Kaynaştırılan görüntü incelendiğinde su sınıfının orijinale göre daha karanlık ve yeşil alan sınıfının orijinale göre daha maviye yakın olduğu görülmektedir. Kaynaştırılmış görüntü uygulama kapsamındaki sınıflandırma yöntemlerine göre aynı imzalar kullanılarak sınıflandırıldığında elde edilen sınıflandırma doğrulukları Şekil 54' de gösterilmiştir. Bu şekilde de görüldüğü üzere bu yöntem sınıflandırma performansını düşüren bir diğer yöntemdir. Çay sınıfı en iyi Rastgele Orman sınıflandırıcısında sınıflandırılırken (% 68) fındık sınıfı en iyi Maksimum Benzerlik (% 51), orman sınıfı ise en iyi Yapay Sinir Ağları sınıflandırıcısında (% 58) sınıflandırılmıştır. Orman sınıfının bütün sınıflandırma yöntemlerinde diğer sınıflara karıştığı gözlemlenmiştir. Ayrıca önceki yöntemlerde olduğu gibi Multiplicative yöntemi ile kaynaştırılmış görüntü sınıflandırıldığında yer yer yol ve su sınıflarının karıştığı görülmektedir. Genel anlamda bu kaynaştırma yöntemi sınıflandırma performansına olumsuz etki etmektedir.




Şekil 54. Orijinal görüntü ve Multiplicative kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Worldview-2 MS – Worldview-2 Pan)




Şekil 55. Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Multiplicative kaynaştırılmış görüntüsü (c), Multiplicative kaynaştırılmış görüntüsünün sınıflandırılması (d) (Worldview-2 MS – Worldview-2 Pan)

Landsat ETM+ çok bantlı görüntüsü ve aynı uyduya ait pankromatik bandın Multiplicative kaynaştırma yöntemi ile kaynaştırılmasıyla elde edilen görüntünün sınıflandırma performansı Şekil 57’ de gösterilmiştir. Şekil 57’ de orijinal görüntü ile kaynaştırılmış görüntü incelendiğinde her iki görüntü arasındaki renk farklılıkları açıkça görülmektedir. Multiplicative kaynaştırılmış görüntüsünün bütün sınıflandırma yöntemleriyle elde edilen sınıflandırılmış görüntülerinde tüm sınıfların birbirleriyle karıştığı gözlemlenmiştir. Toprak ve orman sınıfları en yüksek % 86 ve % 84 başarı oranlarıyla Destek Vektör Makineleri sınıflandırıcısında sınıflandırılırken, kent sınıfı % 95 başarı ile Rastgele Orman sınıflandırıcısında ve su sınıfı % 88 başarı ile Maksimum Benzerlik sınıflandırıcısında sınıflandırılmıştır.




Şekil 56. Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Multiplicative kaynaştırılmış görüntüsü (c), Multiplicative kaynaştırılmış görüntüsünün sınıflandırılması (d) (Landsat ETM+ MS – Landsat ETM+ Pan)




Şekil 57. Orijinal görüntü ve Multiplicative kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Landsat ETM+ MS – Landsat ETM+ Pan)

Multiplicative kaynaştırma yöntemi kullanılarak Ikonos veri setinden elde edilen kaynaştırılmış görüntünün sınıflandırma doğrulukları Şekil 58’ de gösterilmiştir. Şekil incelendiğinde bu kaynaştırma yönteminin renk yapısını bu veri seti için de bozduğu görülmektedir. Bina ve yeşil alan sınıfları Destek Vektör Makineleri sınıflandırıcısı kullanılarak sınıflandırıldığında sırasıyla % 71 ve % 83 başarıyla diğer sınıflardan

ayrılabilmiştir. Gölge sınıfı % 85 doğrulukla Yapay Sinir Ağları sınıflandırıcısı ile sınıflandırılırken yol sınıfı % 74 ile en iyi En Yakın Mesafe sınıflandırıcısı ile sınıflandırılabilmiştir.




Şekil 58. Orijinal görüntü ve Multiplicative kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Ikonos MS – Ikonos Pan)




Şekil 59. Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Multiplicative kaynaştırılmış görüntüsü (c), Multiplicative kaynaştırılmış görüntüsünün sınıflandırılması (d) (Ikonos MS – Ikonos Pan)

İkonos çok bantlı görüntüsü ve QBPan görüntüsü Multiplicative yöntemiyle kaynaştırıldığında elde edilen kaynaştırılmış görüntü bu uygulama kapsamındaki sınıflandırma yöntemleriyle sınıflandırıldığında elde edilen genel sınıflandırma doğrulukları Şekil 61’ de gösterilmiştir. Rastgele Orman sınıflandırıcısı bina sınıfını % 67 oranla en iyi sınıflandırırken Maksimum Benzerlik sınıflandırıcısı yeşil alan sınıfını % 74 oranla en iyi sınıflandırmıştır. Gölge ve yol sınıflarını en iyi sınıflandıran sınıflandırıcılar ise sırasıyla % 65 ve % 81 doğruluklarla Yapay Sinir Ağları ve İkili Kodlama sınıflandırıcılarıdır. Şekil 58’ de bu kaynaştırma yönteminin sınıflandırma performansını düşürdüğü görülmektedir.



Şekil 60. Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Multiplicative kaynaştırılmış görüntüsü (c), Multiplicative kaynaştırılmış görüntüsünün sınıflandırılması (d) (İkonos MS – QBPan)




Şekil 61. Orjinal görüntü ve Multiplicative kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Ikonos MS – QBPan)


3.2.6. PCA Kaynaştırması

Worldview-2 veri setinin PCA yöntemi ile kaynaştırılmasıyla elde edilen görüntü incelendiğinde orijinal görüntüye göre renk farklılıkları göze çarpmaktadır. Kaynaştırılmış görüntüde yol sınıfında spektral distorsiyonlar görülmektedir. Bu yöntemle elde edilen kaynaştırılmış görüntüde de yeşil alanların renklerinin daha maviye yaklaştığı görülmektedir. Kaynaştırılmış görüntü uygulama kapsamındaki sınıflandırma yöntemlerine göre aynı imzalar kullanılarak sınıflandırıldığında elde edilen sınıflandırma doğrulukları Şekil 63’ de gösterilmiştir. Bu sınıflandırma doğruluklarına göre en yüksek sınıflandırma doğruluğunu veren yöntemler % 64’ lük oranla Destek Vektör Makineleri ve Yapay Sinir Ağları yöntemleridir. Çay sınıfı en yüksek sınıflandırma doğruluğunu % 62’ lik oranla Yapay Sinir Ağları sınıflandırıcısında göstermiştir. Fındık sınıfı en yüksek sınıflandırma doğruluğunu % 58 ile Maksimum Benzerlik yönteminde, orman sınıfı ise en yüksek sınıflandırma doğruluğunu sırasıyla % 56 ile Yapay Sinir Ağları ve Destek Vektör Makineleri sınıflandırıcısında göstermiştir. En Yakın Mesafe ve İkili Kodlama yöntemlerinde bu sınıfların birbirlerine sıklıkla karıştığı gözlemlenmiştir. Bütün sınıflandırma yöntemlerinde su sınıfının fındık ve yol sınıfı ile karıştığı gözlemlenmiştir. PCA yöntemi ile görüntü kaynaştırma işleminin görüntüdeki spektral yapıyı bozduğuna dair en önemli kanıtlardan bir tanesi de budur. Toprak, bina ve kayalık sınıfları ise En Yakın Mesafe sınıflandırma yönteminde diğer yöntemlere göre daha fazla birbirlerine karıştıkları gözlemlenmektedir. Gölge sınıfı ise bütün sınıflandırma yöntemlerinde orman sınıfı ile karışmaktadır. Gölge sınıfı en yüksek sınıflandırma doğruluğunu % 93 ile Rastgele Orman sınıflandırma yönteminde göstermektedir. Sınıflandırma ile görüntüdeki bina topluluklarının belirlenmesinde genel anlamda başarı sağlanırken özellikle En yakın

Mesafe yönteminde bina sınıfının piksel piksel diğer sınıflara karıştığı görülmektedir. Genel olarak bu görüntü sınıflandırma performansına olumsuz etki etmektedir.




Şekil 62. Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), PCA kaynaştırılmış görüntüsü (c), PCA kaynaştırılmış görüntüsünün sınıflandırılması (d) (Worldview-2 MS – Worldview-2 Pan)




Şekil 63. Orijinal görüntü ve PCA kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Worldview-2 MS – Worldview-2 Pan)

Landsat ETM+ veri setinin PCA kaynaştırma yöntemiyle kaynaştırılmasıyla elde edilen görüntü bu uygulama kapsamındaki sınıflandırma yöntemleriyle sınıflandırıldığında elde edilen genel sınıflandırma doğrulukları Şekil 65’ de gösterilmiştir. Bu sonuçlara göre bu kaynaştırma yöntemi bu veri seti için En Yakın Mesafe, Rastgele Orman, Maksimum Benzerlik ve Yapay Sinir Ağları sınıflandırıcılarının doğruluklarını azaltırken, Destek Vektör Makineleri ve İkili Kodlama sınıflandırıcılarının doğruluklarına etki etmemiştir. Yapay Sinir Ağları sınıflandırıcısında kent ve toprak sınıflarının, Maksimum Benzerlik sınıflandırıcısında kent ve toprak sınıflarının karıştığı görülmektedir. İkili Kodlama ve En Yakın Mesafe sınıflandırma yöntemleriyle elde edilen sınıflandırılmış görüntülerde ise bütün sınıfların birbirleriyle karışıkları görülmektedir. Toprak, kent, su ve orman sınıfları sırasıyla % 93, % 97, % 97 ve % 88 doğruluklarla Destek Vektör Makineleri sınıflandırıcısında en yüksek sınıflandırma doğruluklarını göstermiştir.




Şekil 64. Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), PCA kaynaştırılmış görüntüsü (c), PCA kaynaştırılmış görüntüsünün sınıflandırılması (d) (Landsat ETM+ MS – Landsat ETM+ Pan)




Şekil 65. Orjinal görüntü ve PCA kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Landsat ETM+ MS – Landsat ETM+ Pan)

PCA kaynaştırma yöntemi ile elde edilen görüntüler sınıflandırıldığında yüksek sınıflandırma performansına ulaşamamıştır. PCA kaynaştırma yöntemiyle İkonos veri setinden elde edilen kaynaştırılmış görüntü bu uygulama kapsamındaki sınıflandırma yöntemleriyle sınıflandırıldığında elde edilen genel sınıflandırma doğrulukları Şekil 66’ da gösterilmiştir. Sınıflandırılmış görüntüler incelendiğinde yol sınıfının bütün sınıflandırılmış görüntülerde diğer sınıflara karıştığı gözlemlenmiştir. Ayrıca farklı renklerdeki bina çatıları burada da sınıflandırmayı güçleştirmiştir. Gölge sınıfını en iyi ayıran yöntem % 84 doğrulukla Maksimum Benzerlik yöntemi olurken bina sınıfını en iyi ayıran yöntem % 75 doğrulukla Destek Vektör Makineleri olmuştur. Yeşil alan ve yol sınıfları ise % 76 ve % 74 doğruluklarla en başarılı şekilde En Yakın Mesafe sınıflandırıcısı kullanılarak sınıflandırılmıştır.




Şekil 66. Orjinal görüntü ve PCA kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (İkonos MS – İkonos Pan)




Şekil 67. Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), PCA kaynaştırılmış görüntüsü (c), PCA kaynaştırılmış görüntüsünün sınıflandırılması (d) (Ikonos MS – Ikonos Pan)

PCA yöntemiyle Ikonos ve QBPan görüntülerinden elde edilen kaynaştırılmış görüntü bu uygulama kapsamındaki sınıflandırma yöntemleriyle sınıflandırıldığında elde edilen genel sınıflandırma doğrulukları Şekil 68’ de gösterilmiştir. Bina ve yol sınıfları sırasıyla % 71 ve % 77 doğruluklarla en iyi Destek Vektör Makineleri ile diğer sınıflardan ayrılırken yeşil alan sınıfı diğer sınıflardan en başarılı şekilde (% 84) Rastgele Orman sınıflandırıcısı ile ayrılmıştır. Gölge sınıfını en başarılı şekilde sınıflandıran sınıflandırıcı ise % 85 doğrulukla Yapay Sinir Ağları sınıflandırıcısı olmuştur.



Şekil 68. Orijinal görüntü ve PCA kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Ikonos MS – QBPan)




Şekil 69. Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), PCA kaynaştırılmış görüntüsü (c), PCA kaynaştırılmış görüntüsünün sınıflandırılması (d) (Ikonos MS – QBpan)


3.2.7. Dalgacık Dönüşümü Kaynaştırması

Worldview-2 çok bantlı görüntüsü ve aynı uydudan alınan pankromatik görüntünün Dalgacık Dönüşümü ile kaynaştırılmasıyla elde edilen kaynaştırılmış görüntü uygulama kapsamındaki sınıflandırma yöntemlerine göre sınıflandırıldığında elde edilen sınıflandırma doğrulukları Şekil 71’ de gösterilmiştir. Dalgacık Dönüşümü görüntü kaynaştırma yöntemi bu sonuçlar ışığında sınıflandırma performansını arttıran bir diğer yöntemdir. Kaynaştırılan görüntüdeki yol alanlarında PCA yönteminde olduğu gibi spektral distorsiyonlar bulunmaktadır. Destek Vektör Makineleri, Maksimum Benzerlik ve Yapay Sinir Ağları sınıflandırıcıları ile elde edilen sonuçlarda yer yer su sınıfı ile orman ve kayalık sınıfları karıştığı görülmektedir. Fındık ve çay sınıflarının diğer sınıflardan ayrılabilmesini sağlayan en iyi yöntem sırasıyla % 59 ve % 76’ lık oranla Destek Vektör Makineleri yöntemidir. Orman sınıfını en iyi ayıran yöntem ise % 74 sınıflandırma doğruluğu ile Yapay Sinir Ağları sınıflandırıcısıdır. Toprak, kayalık ve yol sınıfları Destek Vektör Makineleri ve Yapay Sinir Ağları sınıflandırıcılarında diğer sınıflandırıcılara

nazaran daha yüksek doğrulukta sınıflandırılmışlardır. Yol ve kayalık sınıflarını en iyi ayıran sınıflandırıcı Yapay Sinir Ağları sınıflandırıcısı (% 76 ve % 96), bina sınıfını en iyi ayıran sınıflandırıcı İkili Kodlama (% 90) sınıflandırıcısı ve toprak sınıfını en iyi ayıran sınıflandırıcı % 91 ile Destek Vektör Makineleri sınıflandırıcısıdır. Bu yöntemin sınıflandırılmasında en kötü sonucu En Yakın Mesafe yöntemi vermiştir. Bu sınıflandırma sonucuna bakıldığı zaman tüm sınıfların birbirlerine karıştığı gözlemlenmektedir. Genel anlamda bu kaynaştırma yöntemi sınıflandırma performansına olumlu etki etmektedir, ancak spektral yapının korunmasını yeterince sağlayamamaktadır.




Şekil 70. Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Dalgacık Dönüşümü kaynaştırılmış görüntüsü (c), Dalgacık Dönüşümü kaynaştırılmış görüntüsünün sınıflandırılması (d) (Worldview-2 MS – Worldview-2 Pan)




Şekil 71. Orjinal görüntü ve Dalgacık Dönüşümü kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Worldview-2 MS – Worldview-2 Pan)

Wavelet kaynaştırma yöntemiyle Landsat ETM+ çok bantlı görüntüsü ve pankromatik bandından elde edilen görüntü bu uygulama kapsamındaki sınıflandırma yöntemleriyle sınıflandırıldığında elde edilen genel sınıflandırma doğrulukları Şekil 72’ de gösterilmiştir. Şekil 72 incelendiğinde Dalgacık Dönüşümü kaynaştırma yönteminin Destek Vektör Makineleri, Yapay Sinir Ağları ve Maksimum Benzerlik sınıflandırıcılarının sınıflandırma performanslarını artırırken, En Yakın Mesafe, Rastgele Orman ve İkili Kodlama sınıflandırıcılarının sınıflandırma performanslarını düşürdüğü görülmektedir. Dalgacık Dönüşümü kaynaştırılmış görüntüsünün Rastgele Orman yöntemi ile sınıflandırılmasıyla elde edilen sınıflandırılmış görüntüde su sınıfı ile orman ve kent sınıfının karıştığı görülmektedir. Yapay Sinir Ağları ile sınıflandırılan kaynaştırılmış görüntüde ise su sınıfının yer yer orman sınıfı ile karıştığı, Maksimum Benzerlik ile sınıflandırılan kaynaştırılmış görüntüde ise su ve kent sınıflarının karıştığı görülmektedir. Su ve orman sınıflarının sırasıyla % 96 ve % 93 sınıflandırma doğrulukları ile en yüksek Destek Vektör Makineleri sınıflandırıcısında, toprak sınıfının % 83 ile Yapay Sinir Ağları ve Rastgele Orman sınıflandırıcılarında ve kent sınıfının % 85 ile Yapay Sinir Ağları sınıflandırıcısında sınıflandırıldığı belirlenmiştir.




Şekil 72. Orjinal görüntü ve Dalgacık Dönüşümü kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Landsat ETM+ MS – Landsat ETM+ MS Pan)




Şekil 73. Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Dalgacık Dönüşümü kaynaştırılmış görüntüsü (c), Dalgacık Dönüşümü kaynaştırılmış görüntüsünün sınıflandırılması (d) (Landsat ETM+ MS – Landsat ETM+ Pan)

İkonos veri setinden Dalgacık Dönüşümü kaynaştırması ile elde edilen kaynaştırılmış görüntü bu uygulama kapsamındaki sınıflandırma yöntemleriyle sınıflandırıldığında elde edilen genel sınıflandırma doğrulukları Şekil 75’ de gösterilmiştir. Şekil incelendiğinde bu yöntemin sınıflandırma performansını arttıran bir diğer yöntem olduğu görülmektedir. Yol sınıfı diğer sınıflara Destek Vektör Makineleri ve Yapay Sinir Ağları sınıflandırıcılarında daha az karışmaktadır. Gölge ve bina sınıfları genelde başarılı şekilde sınıflandırılmış fakat En Yakın Mesafe ve İkili Kodlama sınıflandırıcılarında yüksek başarı sağlanamamıştır. Gölge sınıfı Maksimum Benzerlik sınıflandırıcısı kullanılarak % 92 doğrulukla diğer sınıflardan en başarılı şekilde ayrılabilmiştir. Yeşil alan ve bina sınıflarını en iyi sınıflandıran sınıflandırıcı ise sırasıyla % 93 ve % 88 doğruluklarla Destek Vektör Makineleri sınıflandırıcısı olurken yol sınıfını en iyi ayıran sınıflandırıcı % 84 başarıyla Rastgele Orman sınıflandırıcısı olmuştur.




Şekil 74. Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Dalgacık Dönüşümü kaynaştırılmış görüntüsü (c), Dalgacık Dönüşümü kaynaştırılmış görüntüsünün sınıflandırılması (d) (Ikonos MS – Ikonos Pan)




Şekil 75. Orijinal görüntü ve Dalgacık Dönüşümü kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Ikonos MS – Ikonos Pan)

Dalgacık Dönüşümü kullanılarak Ikonos çok bantlı görüntüsü ve QBPan görüntüsünün kaynaştırılmasıyla elde edilen kaynaştırılmış görüntü bu uygulama kapsamındaki sınıflandırma yöntemleriyle sınıflandırıldığında elde edilen genel sınıflandırma doğrulukları Şekil 77' de gösterilmiştir. Yeşil alan ve yol sınıflarını en başarılı sınıflandıran sınıflandırıcı sırasıyla % 92 ve % 90 doğruluklarla Maksimum Benzerlik sınıflandırıcısı olmuştur. Bina sınıfını en iyi ayıran sınıflandırıcı ise % 83

doğrulukla Destek Vektör Makineleri sınıflandırıcısı olurken gölge sınıfını en başarılı sınıflandıran sınıflandırıcı % 84 doğrulukla Yapay Sinir Ağları sınıflandırıcısı olmuştur.




Şekil 76. Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Dalgacık Dönüşümü kaynaştırılmış görüntüsü (c), Dalgacık Dönüşümü kaynaştırılmış görüntüsünün sınıflandırılması (d) (Ikonos MS – QBPan)




Şekil 77. Orijinal görüntü ve Dalgacık Dönüşümü kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Ikonos MS – QBPan)

3.2.8. CN Kaynaştırması

Worldview-2 çok bantlı görüntüsü ve aynı uydudan alınan pankromatik bandın CN yöntemiyle kaynaştırılmasıyla elde edilen kaynaştırılmış görüntüdeki renkler orijinal görüntüye göre daha açık tonlardadır. Kaynaştırılmış görüntü incelendiğinde bazı orman alanları ve gölgelik alanların renklerinin beyaz renkle seyreltildiği gözlemlenmektedir. Yol ve binalarda da bazı spektral distorsiyonlar göze çarpmaktadır. Kaynaştırılmış görüntü uygulama kapsamındaki sınıflandırma yöntemlerine sınıflandırıldığında elde edilen sınıflandırma doğrulukları Şekil 78’ de gösterilmiştir. Şekil 78’ de de görüldüğü üzere bu kaynaştırma yöntemi Destek Vektör Makineleri ve Rastgele orman sınıflandırıcılarının orijinal görüntüye göre sınıflandırma doğruluklarını artırırken En Yakın Mesafe ve Maksimum Benzerlik sınıflandırıcılarının doğruluklarını azaltmakta, Yapay Sinir Ağları ve İkili Kodlama sınıflandırıcılarının doğruluklarına etki etmemektedir. Destek Vektör Makineleri sınıflandırıcısı çay sınıfı için en yüksek sınıflandırma sonucunu vermiştir (% 78). Fındık sınıfını diğer sınıflardan ayıran en iyi sınıflandırıcı % 55 ile Destek Vektör Makineleri sınıflandırıcısı, orman sınıfını diğer sınıflardan ayıran en iyi sınıflandırıcı ise % 68 ile Rastgele Orman sınıflandırıcısıdır. Bina, toprak ve yol sınıflarını ayırmada en başarılı sınıflandırıcı sırasıyla % 83, % 88 ve % 73 sınıflandırma doğrulukları ile Destek Vektör sınıflandırıcısıdır. Gölge sınıfı ise sınıflandırılmış görüntülerde orman ve kayalık sınıfı ile yer yer karışmakta olup % 93 doğrulukla en iyi Maksimum Benzerlik sınıflandırıcısında sınıflandırılmıştır.




Şekil 78. Orijinal görüntü ve CN kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Worldview-2 MS – Worldview-2 Pan)




Şekil 79. Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), CN kaynaştırılmış görüntüsü (c), CN kaynaştırılmış görüntüsünün sınıflandırılması (d) (Worldview-2 MS – Worldview-2 Pan)

CN kaynaştırma yöntemiyle Landsat ETM+ veri setinden elde edilen görüntü bu uygulama kapsamındaki sınıflandırma yöntemleriyle sınıflandırıldığında elde edilen genel sınıflandırma doğrulukları Şekil 81’ de gösterilmiştir. Bu kaynaştırma yöntemi Destek Vektör Makineleri, Yapay Sinir Ağları, Maksimum Benzerlik ve Rastgele Orman sınıflandırma yöntemlerinin sınıflandırma doğruluklarını arttırırken, En Yakın Mesafe ve İkili Kodlama Yöntemlerinin sınıflandırma doğruluklarını azaltmıştır. Kaynaştırma işleminden önce su sınıfı ile orman sınıfı birbirlerine karışmazken kaynaştırmadan sonra bu iki sınıfın birbirlerine karıştıkları gözlemlenmiştir. Toprak, kent ve orman sınıflarının en yüksek sınıflandırma doğruluklarını sırasıyla % 96, % 97 ve % 91’ lik oranlarla Destek Vektör Makineleri sınıflandırıcısında, su sınıfının ise en yüksek sınıflandırma doğruluğunu % 93 ile Rastgele Orman sınıflandırıcısında gösterdiği belirlenmiştir.




Şekil 80. Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), CN kaynaştırılmış görüntüsü (c), CN kaynaştırılmış görüntüsünün sınıflandırılması (d) (Landsat ETM+ MS – Landsat ETM+ Pan)




Şekil 81. Orijinal görüntü ve CN kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Landsat ETM+ MS – Landsat ETM+ Pan)

CN kaynaştırma yöntemiyle Ikonos veri setinden elde edilen görüntü bu uygulama kapsamındaki sınıflandırma yöntemleriyle sınıflandırıldığında elde edilen genel sınıflandırma doğrulukları Şekil 83’ de gösterilmiştir. Şekil 83 incelendiğinde bu kaynaştırma yönteminin Destek Vektör Makineleri, Yapay Sinir Ağları, Rastgele Orman ve En Yakın Mesafe sınıflandırıcılarının genel doğruluklarını arttırırken Maksimum Benzerlik ve İkili Kodlama sınıflandırıcılarının genel doğruluklarını deęiřtirmedięi görölmektedir.

Bu yöntem ile elde edilen kaynaştırılmış görüntü konumsal detay bakımından oldukça zengin renk yapısı bakımından orijinal çok bantlı görüntüden farklılıklar göstermektedir. Bina, yeşil alan ve yol sınıflarını diğer sınıflardan ayırmayı başaran en iyi yöntem sırasıyla % 80, % 83 ve % 89 doğruluklarla Yapay Sinir Ağları sınıflandırma yöntemidir. Gölge sınıfı ise Rastgele Orman sınıflandırıcısında neredeyse tam başarı ile (% 97) sınıflandırılabilmiştir.




Şekil 82. Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), CN kaynaştırılmış görüntüsü (c), CN kaynaştırılmış görüntüsünün sınıflandırılması (d) (Ikonos MS – Ikonos Pan)




Şekil 83. Orijinal görüntü ve CN kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Ikonos MS – Ikonos Pan)

İkonos çok bantlı görüntüsü ve QBPan görüntüsünün CN yöntemiyle kaynaştırılmasıyla elde edilen görüntü bu uygulama kapsamındaki sınıflandırma yöntemleriyle sınıflandırıldığında elde edilen genel sınıflandırma doğrulukları Şekil 85’ de gösterilmiştir. Şekil 85 incelendiğinde CN kaynaştırma yönteminin Rastgele Orman, Maksimum Benzerlik, Yapay Sinir Ağları ve Destek Vektör Makineleri sınıflandırıcılarının sınıflandırma doğruluklarını artırırken İkili Kodlama sınıflandırıcısının sınıflandırma doğruluğunu azalttığı ve En Yakın Mesafe sınıflandırıcısının sınıflandırma doğruluğunu değiştirmedeği görülmektedir. Destek Vektör Makineleri sınıflandırıcısı bina sınıfını % 78 doğrulukla en başarılı şekilde sınıflandırmıştır. Rastgele Orman sınıflandırıcısı yeşil alan sınıfını % 86 doğrulukla en başarılı şekilde sınıflandırırken, En Yakın Mesafe sınıflandırıcısı gölge sınıfını ve Maksimum Benzerlik sınıflandırıcısı ise % 84 doğrulukla yol sınıfını en başarılı şekilde sınıflandırmıştır.




Şekil 84. Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), CN kaynaştırılmış görüntüsü (c), CN kaynaştırılmış görüntüsünün sınıflandırılması (d) (İkonos MS – QBPan)




Şekil 85. Orjinal görüntü ve CN kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Ikonos MS – QBPan)

3.2.9. Gram-Schmidt Kaynaştırması

Gram-Schmidt yöntemi ile Worldview-2 veri setinden elde edilen kaynaştırılmış görüntü incelendiğinde bina ve yol alanlarında bir takım spektral distorsiyonlar görülmektedir. Kaynaştırılmış görüntü uygulama kapsamındaki sınıflandırma yöntemlerine göre sınıflandırıldığında elde edilen sınıflandırma doğrulukları Şekil 87’ de gösterilmiştir. Bu sonuçlara göre bu kaynaştırma yönteminin sınıflandırma performansını arttırdığı görülmektedir. Çay sınıfı Destek Vektör Makineleri sınıflandırıcısında en yüksek sınıflandırma doğruluğu ile (% 78) diğer sınıflardan ayırt edilebilmiştir. Fındık sınıfı ise % 58’ lik oranla en iyi Yapay Sinir Ağları sınıflandırıcısında sınıflandırılırken orman sınıfı ise en yüksek sınıflandırma doğruluğunu % 75 ile yine Destek Vektör Makineleri sınıflandırıcısında göstermiştir. Deniz sınıfı tüm sınıflandırılmış görüntülerde kayalık ve yol sınıfları ile bazı bölgelerde birbirine karışmaktadır. Toprak ve yol sınıfı görüntü kaynaştırmadan önce birbirlerinden ayırt edilebilirken görüntü kaynaştırmadan sonra birbirlerine karıştıkları gözlenmiştir. Bu durum orijinal görüntü ve kaynaştırılmış görüntüye ait sınıflandırılmış görüntülerde açıkça belli olmaktadır. Yapay Sinir Ağları yöntemi toprak sınıfını % 83 ile ayırmayı başarırken, Destek Vektör Makineleri sınıflandırma yöntemi toprak ve yol sınıfını % 71 ile ayırmayı başarmıştır. Yapay Sinir Ağları yöntemi gölge sınıfını neredeyse tam başarıyla (% 96) diğer sınıflardan ayırabilmiştir.




Şekil 86. Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Gram-Schmidt kaynaştırılmış görüntüsü (c), Gram-Schmidt kaynaştırılmış görüntüsünün sınıflandırılması (d) (Worldview-2 MS – Worldview-2 Pan)




Şekil 87. Orijinal görüntü ve Gram-Schmidt kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Worldview-2 MS – Worldview-2 Pan)

Landsat ETM+ çok bantlı görüntüsü ve aynı uydudan alınan pankromatik görüntünün kaynaştırılmasıyla elde edilen kaynaştırılmış görüntü bu çalışma kapsamındaki

sınıflandırma yöntemleriyle sınıflandırıldığında elde edilen genel sınıflandırma doğrulukları Şekil 89’ da görülmektedir. Şekil 89 incelendiğinde Gram-Schmidt kaynaştırma yönteminin Destek Vektör Makineleri, Maksimum Benzerlik, Rastgele Orman ve İkili Kodlama sınıflandırma yöntemlerinin sınıflandırma performansını arttırırken, Yapay Sinir Ağları yönteminin sınıflandırma performansını azalttığı ve En Yakın Mesafe yönteminin sınıflandırma performansına etki etmediği görülmektedir. Orijinal görüntü ve kaynaştırılmış görüntü Yapay Sinir Ağları sınıflandırıcısı ile sınıflandırıldığında su ve orman sınıflarının birbirlerine karıştığı görülmektedir. Maksimum Benzerlik ve Rastgele Orman sınıflandırıcıları ile sınıflandırılan görüntülerde de kent ve su sınıflarının birbirlerine karıştıkları gözlemlenmiştir. Toprak (% 96), kent (% 90) ve orman (% 96) sınıfları en iyi Destek Vektör Makineleri sınıflandırıcısında diğer sınıflardan ayrılabilmiştir. Su sınıfı ise % 96’ lık oranla en iyi Rastgele Orman sınıflandırıcısında sınıflandırılmıştır.




Şekil 88. Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Gram-Schmidt kaynaştırılmış görüntüsü (c), Gram-Schmidt kaynaştırılmış görüntüsünün sınıflandırılması (d) (Landsat ETM+ MS – Landsat ETM+ Pan)




Şekil 89. Orijinal görüntü ve Gram-Schmidt kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Landsat ETM+ MS – Landsat ETM+ Pan)

Gram-Schmidt yönteminin çok bantlı görüntünün spektral yapısına fazla zarar vermeden konumsal detay arttırmada oldukça başarılı olduğu Ikonos veri setinden elde edilen kaynaştırılmış görüntü de görülmektedir. Gram-Schmidt kaynaştırma yöntemiyle elde edilen görüntü bu uygulama kapsamındaki sınıflandırma yöntemleriyle sınıflandırıldığında elde edilen genel sınıflandırma doğrulukları Şekil 90' da gösterilmiştir. Bu yöntem bütün sınıflandırma yöntemlerinin sınıflandırma performanslarını arttırmıştır. Destek Vektör Makineleri sınıflandırıcısı kaynaştırılmış görüntüde oldukça iyi sonuçlar vermiştir. Yeşil alanlar ve binalar bütün sınıflandırıcılarda diğer sınıflara az da olsa karışmaktadır. Gölge ve yeşil alan sınıflarını en yüksek doğrulukla (sırasıyla % 92 ve % 93) sınıflandıran sınıflandırıcı Maksimum Benzerlik sınıflandırıcısı iken bina ve yol sınıflarını en iyi sınıflandıran sınıflandırıcı sırasıyla % 89 ve % 84 doğrulukla Destek Vektör Makineleri sınıflandırıcısı olmuştur.




Şekil 90. Orijinal görüntü ve Gram-Schmidt kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Ikonos MS – Ikonos Pan)




Şekil 91. Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Gram-Schmidt kaynaştırılmış görüntüsü (c), Gram-Schmidt kaynaştırılmış görüntüsünün sınıflandırılması (d) (Ikonos MS – Ikonos Pan)

Ikonos çok bantlı görüntüsü ile QBPan görüntüsünün kaynaştırılmasıyla elde edilen kaynaştırılmış görüntü bu uygulama kapsamındaki sınıflandırma yöntemleriyle sınıflandırıldığında elde edilen genel sınıflandırma doğrulukları Şekil 92’ de gösterilmiştir. Bina, yeşil alan ve yol sınıflarını en yüksek doğrulukla sınıflandıran sınıflandırıcı sırasıyla % 85, % 94 ve % 91 doğruluklarla Destek Vektör Makineleri sınıflandırıcısı olmuştur. Rastgele Orman sınıflandırıcısı ise gölge sınıfını % 90 doğrulukla en başarılı şekilde sınıflandırmıştır.



Şekil 92. Orijinal görüntü ve Gram-Schmidt kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Ikonos MS – QBPan)




Şekil 93. Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Gram-Schmidt kaynaştırılmış görüntüsü (c), Gram-Schmidt kaynaştırılmış görüntüsünün sınıflandırılması (d) (Ikonos MS – QBPan)


3.2.10. Kriter Tabanlı Görüntü Kaynaştırması

Kriter Tabanlı görüntü kaynaştırma yöntemiyle Worldview-2 veri setinden elde edilen kaynaştırılmış görüntü uygulama kapsamındaki sınıflandırma yöntemlerine göre sınıflandırıldığında elde edilen sınıflandırma doğrulukları Şekil 94’ de gösterilmiştir. Bu kaynaştırma yönteminin sınıflandırma performansına olumlu etki yaptığı belirlenmiştir. Bu görüntü sınıflandırıldığında en yüksek doğruluğu % 75’ lik oranla Destek Vektör Makineleri sağlarken, Rastgele Orman sınıflandırma yöntemi % 74’lük oranla en iyi ikinci yöntem olmuşlardır. Bu görüntü görsel olarak incelendiğinde görüntüdeki spektral distorsiyonların renk tabanlı görüntü kaynaştırma yöntemlerine göre daha az olduğu gözlemlenmiştir. Rastgele Orman, Destek Vektör Makineleri, Yapay Sinir Ağları ve Maksimum Benzerlik yöntemleri ile görüntü sınıflandırıldığında görüntüdeki büyük çay bahçelerinin diğer sınıflardan başarılı denilebilecek düzeyde ayırt edilebildiği görülmektedir. Fakat yine de çay sınıfı yer yer fındık ve orman sınıfına karışmaktadır. Maksimum Benzerlik Yöntemi ile sınıflandırmada çay sınıfının diğer sınıflara oranla (%)

76) daha yüksek doğrulukla sınıflandırıldığı belirlenmiştir. Fındık sınıfı en yüksek sınıflandırma doğruluğunu % 61 ile Maksimum Benzerlik ve Destek Vektör Makineleri yöntemlerinde gösterirken, orman sınıfı en yüksek sınıflandırma doğruluğunu % 75 ile yine Destek Vektör Makineleri sınıflandırma yönteminde göstermektedir. Gölge sınıfı en yüksek sınıflandırma doğruluğunu % 90 ile Destek Vektör Makineleri ve Yapay Sinir Ağları sınıflandırmasında gösterirken En yakın mesafe yönteminde orman sınıfına karıştığı gözlemlenmiştir. Kaynaştırılmış görüntüde su yüzeyindeki bazı maddeler suyun renk yapısına etki etmiştir. Bu nedenden dolayı sınıflandırılmış görüntülerde su sınıfı bazı bölgelerde yol sınıfı ile karışmıştır. Toprak sınıfı en yüksek sınıflandırma doğruluğunu % 91' lik oranla Destek Vektör Makineleri ve Maksimum Benzerlik sınıflandırıcısında göstermiştir. Bina ve yol sınıfları birbirlerine yer yer karışmakla beraber bu iki sınıf için en yüksek sınıflandırma doğrulukları sırasıyla % 93 ve % 71 olmak üzere Rastgele Orman ve Yapay Sinir Ağları sınıflandırıcılarında görülmektedir.




Şekil 94. Orjinal görüntü ve Kriter Tabanlı kaynaştırılmış görüntünün sınıflandırma doğrulukları (Worldview-2 MS – Worldview-2 Pan)




Şekil 95. Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Kriter Tabanlı kaynaştırılmış görüntü (c), Kriter Tabanlı kaynaştırılmış görüntünün sınıflandırılması (d) (Worldview-2 MS – Worldview-2 Pan)

Kriter Tabanlı kaynaştırma yöntemiyle Landsat ETM+ veri setinden elde edilen kaynaştırılmış görüntü bu uygulama kapsamındaki sınıflandırma yöntemleriyle sınıflandırıldığında elde edilen genel sınıflandırma doğrulukları Şekil 97’ de görülmektedir. Şekil 97’ de de görüldüğü üzere bu yöntem tüm sınıflandırma yöntemlerinin doğruluklarını arttırmaktadır. Rastgele Orman ve Maksimum Benzerlik yöntemleri ile sınıflandırılan görüntülerde yer yer kent ve su sınıflarının karıştığı görülmektedir. Destek Vektör Makineleri ve Yapay Sinir Ağları yöntemleri tüm sınıfların birbirlerinden ayrılabilmesinde daha başarılı olmuşlardır. Destek Vektör Makineleri sınıflandırma yöntemi % 86 ve % 87’ lik oranla toprak ve kent sınıflarını, Yapay Sinir Ağları sınıflandırma yöntemi ise % 94 ve % 95’ lik oranla su ve orman sınıflarını diğer sınıflardan en başarılı şekilde ayırabilmiştir.




Şekil 96. Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Kriter Tabanlı kaynaştırılmış görüntü (c), Kriter Tabanlı kaynaştırılmış görüntünün sınıflandırılması (d) (Landsat ETM+ MS – Landsat ETM+ Pan)




Şekil 97. Orijinal görüntü ve Kriter Tabanlı kaynaştırılmış görüntünün sınıflandırma doğrulukları (Landsat ETM+ MS – Landsat ETM+ Pan)

Kriter Tabanlı Görüntü Kaynaştırma yöntemi spektral yapıya oldukça az zarar vererek konumsal detayları zenginleştirmektedir. Bu yöntem spektral yapıya fazla zarar vermemesinden dolayı sınıflandırma performansına olumlu etki eden bir kaynaştırma yöntemidir. Bu durum Ikonos veri setlerinden elde edilen kaynaştırılmış görüntü için de geçerlidir. Kriter Tabanlı Görüntü Kaynaştırma yöntemiyle elde edilen kaynaştırılmış

görüntü bu uygulama kapsamındaki sınıflandırma yöntemleriyle sınıflandırıldığında elde edilen genel sınıflandırma doğrulukları Şekil 98’ de gösterilmiştir. Kaynaştırılmış görüntünün bütün sınıflandırıcılarla sınıflandırılmasıyla elde edilen görüntülerde yol sınıfı diğer sınıflara az da olsa karışmaktadır. Gölge ve bina sınıfları ise yüksek doğrulukla sınıflandırılmışlardır. Bina, yeşil alan ve yol sınıfları sırasıyla % 90, % 96 ve % 86 genel doğruluklarla en iyi Destek Vektör Makineleri sınıflandırıcısında sınıflandırılırken gölge sınıfı en iyi % 88 doğrulukla Rastgele Orman sınıflandırıcısında sınıflandırılmıştır.




Şekil 98. Orjinal görüntü ve Kriter Tabanlı kaynaştırılmış görüntünün sınıflandırma doğrulukları (Ikonos MS – Ikonos Pan)




Şekil 99. Orjinal görüntü (a), Orjinal görüntünün sınıflandırılması (b), Kriter Tabanlı kaynaştırılmış görüntü (c), Kriter Tabanlı kaynaştırılmış görüntünün sınıflandırılması (d) (Ikonos MS – Ikonos Pan)

Kriter Tabanlı Görüntü Kaynaştırma yöntemi spektral yapıyı korumadaki başarısını farklı sensörlerden alınan görüntülerin kaynaştırılmasında da göstermiştir. Ikonos çok bantlı görüntüsü ile QBPan görüntüsünün Kriter Tabanlı Görüntü Kaynaştırma yöntemi ile kaynaştırılmasıyla elde edilen kaynaştırılmış görüntü bu çalışma kapsamındaki sınıflandırma yöntemleriyle sınıflandırıldığında elde edilen genel sınıflandırma doğrulukları Şekil 101’ de gösterilmiştir. Yeşil alan ve yol sınıfları diğer sınıflardan en başarılı şekilde (sırasıyla % 84 ve % %91 doğruluklarla) Yapay Sinir Ağları ile ayrılabilirken, bina sınıfı Rastgele Orman (%86), gölge sınıfı ise Destek Vektör Makineleri ile diğer sınıflardan en başarılı şekilde (%85) ayrılabilmiştir.




Şekil 100. Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Kriter Tabanlı kaynaştırılmış görüntü (c), Kriter Tabanlı kaynaştırılmış görüntünün sınıflandırılması (d) (Ikonos MS – QBPan)




Şekil 101. Orijinal görüntü ve Kriter Tabanlı kaynaştırılmış görüntünün sınıflandırma doğrulukları (Ikonos MS – QBPan)

3.2.11. Yeni Yöntem ile Kaynaştırma

Worldview-2 veri setinin yeni yöntem ile kaynaştırılmasıyla elde edilen kaynaştırılmış görüntüde yol, gölge ve yeşil alanlarda spektral bozulmalara rastlanmaktadır. Kaynaştırılmış görüntü ile orijinal çok bantlı görüntü aynı kırmızı-yeşil-mavi bant kombinasyonlarında açıldıklarında kaynaştırılmış görüntünün orijinal görüntüye göre daha açık renk tonlarında olduğu görülmektedir. Kaynaştırılmış görüntü uygulama kapsamındaki sınıflandırma yöntemlerine göre aynı imzalar kullanılarak sınıflandırıldığında elde edilen sınıflandırma doğrulukları Şekil 103’ de gösterilmiştir. Bu sonuçlara göre bu yöntem sınıflandırma performansını başarıyla arttıran bir diğer yöntemdir. Çay sınıfı bütün sınıflandırılmış görüntülerde fındık ve orman sınıfına karışmaktadır. Çay ve orman sınıflarını sırasıyla % 74 ve % 87 başarı ile en iyi ayıran sınıflandırıcı Destek Vektör Makineleri sınıflandırıcısı olarak belirlenmiştir. Fındık sınıfını diğer sınıflardan en iyi ayıran sınıflandırma yöntemi ise % 70’ lik doğrulukla Yapay Sinir Ağları yöntemidir. Sınıflandırılmış görüntülerde kayalık sınıfı gölge ve su sınıfı ile karışma göstermektedir. Gölge sınıfı ise En Yakın Mesafe yöntemi ile sınıflandırılmış görüntüde orman sınıfı ile karışmaktadır. Gölge sınıfı için en iyi sınıflandırma sonucunu % 93 ile Destek Vektör Makineleri sınıflandırıcısı verirken, bina sınıfı için en iyi sınıflandırma sonucunu yine % 93 ile Rastgele Orman sınıflandırıcısı vermiştir. Yol sınıfı bütün sınıflandırılmış görüntülerde yer yer bina sınıfı ile karışma göstermektedir. Yol sınıfı için en iyi sınıflandırma doğruluğunu gösteren yöntem ise % 91 ile Maksimum Benzerlik yöntemidir. En Yakın Mesafe ve İkili Kodlama sınıflandırıcıları ise diğer yöntemlerdeki gibi bu yöntemde de başarısız olmuşlardır.




Şekil 102. Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Yeni Yöntem ile kaynaştırılmış görüntü (c), Yeni Yöntem kaynaştırılmış görüntüsünün sınıflandırılması (d) (Worldview-2 MS – Worldview-2 Pan)




Şekil 103. Orijinal görüntü ve Kriter Tabanlı kaynaştırılmış görüntünün sınıflandırma doğrulukları (Worldview-2 MS – Worldview-2 Pan)

Landsat ETM+ çok bantlı görüntüsü ve aynı uyduya ait pankromatik görüntünün Yeni Yöntem ile kaynaştırılmasıyla elde edilen kaynaştırılmış görüntü bu uygulama kapsamındaki sınıflandırma yöntemleriyle sınıflandırıldığında elde edilen genel sınıflandırma doğrulukları Şekil 105’ de görülmektedir. Bütün sınıflandırılmış görüntülerde kent sınıfı ile toprak sınıfının yer yer karıştığı gözlemlenmektedir. Su sınıfı Yapay Sinir Ağları sınıflandırıcısı kullanılarak diğer sınıflardan en başarılı şekilde ayrılabilmiştir. Su ve orman sınıfları % 94 doğrulukla Yapay Sinir Ağları sınıflandırıcısında sınıflandırılmıştır. Kent sınıfını en iyi sınıflandıran sınıflandırıcı % 90 doğrulukla Destek Vektör Makineleri sınıflandırıcısı olurken toprak sınıfını en iyi sınıflandıran sınıflandırıcı % 86 doğrulukla Rastgele Orman sınıflandırıcısı olmuştur.




Şekil 104. Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Yeni Yöntem kaynaştırılmış görüntü (c), Yeni Yöntem kaynaştırılmış görüntüsünün sınıflandırılması (d) (Landsat ETM+ MS – Landsat ETM+ Pan)




Şekil 105. Orjinal görüntü ve Yeni Yöntem kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Landsat ETM+ MS – Landsat ETM+ Pan)

İkonos veri setinden yeni kaynaştırma yöntemiyle elde edilen kaynaştırılmış görüntü çalışma kapsamındaki sınıflandırma yöntemleriyle sınıflandırıldığında elde edilen genel sınıflandırma doğrulukları Şekil 106’ de gösterilmiştir. Bu yöntem Destek Vektör Makineleri, Maksimum Benzerlik, Rastgele Orman ve En Yakın Mesafe sınıflandırma yöntemlerinin performansını arttırırken Yapay Sinir Ağları sınıflandırma yönteminin performansını azaltmış, İkili Kodlama sınıflandırma yönteminin performansına etki etmemiştir. Sınıflandırılmış görüntülerde yol sınıfı bina sınıfına yer yer karışmaktadır. Gölge, bina, yeşil alan ve yol sınıfları sırasıyla % 93, % 85, % 93 ve % 81 doğruluklarla en iyi Destek Vektör Makineleri sınıflandırıcısında sınıflandırılabilmiştir.




Şekil 106. Orjinal görüntü ve Yeni Yöntem kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (İkonos MS – İkonos Pan)




Şekil 107. Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Yeni Yöntem kaynaştırılmış görüntüsü (c), Yeni Yöntem kaynaştırılmış görüntüsünün sınıflandırılması (d) (Ikonos MS – Ikonos Pan)

Ikonos görüntüsü ile QBPan görüntüsünün Yeni Yöntem ile kaynaştırılmasıyla elde edilen kaynaştırılmış görüntü çalışma kapsamındaki sınıflandırma yöntemleriyle sınıflandırıldığında elde edilen genel doğruluklar Şekil 108’ de gösterilmiştir. Sınıflandırma sonuçlarına göre bina, yeşil alan ve gölge sınıflarını sırasıyla % 84, % 84 ve % 83 doğruluklara Destek Vektör Makineleri, yol sınıfını ise % 74 doğrulukla Maksimum Benzerlik sınıflandırma yöntemi en başarılı şekilde sınıflandırmıştır.



Şekil 108. Orjinal görüntü ve Yeni Yöntem kaynaştırılmış görüntüsünün sınıflandırma doğrulukları (Ikonos MS – QBPan)



Şekil 109. Orijinal görüntü (a), Orijinal görüntünün sınıflandırılması (b), Yeni Yöntem kaynaştırılmış görüntüsü (c), Yeni Yöntem kaynaştırılmış görüntüsünün sınıflandırılması (d) (İkonos MS-QBPan)

3.3. Genel Değerlendirme

Bu çalışma kapsamında aynı sensörden ve farklı sensörlerden elde edilen kaynaştırılmış görüntülerin sınıflandırılması ile kaynaştırma yöntemlerinin spektral yapıları ne derece etkilediği incelenmiştir. Sınıflandırma sonuçları HPF, Gram-Schmidt, Dalgacık Dönüşümü, Ehlers, Yeni Yöntem ve Kriter Tabanlı Görüntü Kaynaştırma yöntemlerinin sınıflandırma performanslarına olumlu etki ettiklerini göstermiştir. CN, IHS, Brovey, Multiplicative ve PCA görüntü kaynaştırma yöntemleri spektral yapıyı korumada başarılı olamamışlardır. Metrik değerleri ve istatistiksel bazı hesaplamalar zaman zaman yanıltıcı sonuçlar vermişlerdir. Örneğin Ehlers görüntü kaynaştırma yöntemi ile elde edilen kaynaştırılmış görüntüler hemen hemen bütün metrik değerlerinden düşük sonuçlar almalarına rağmen Ehlers kaynaştırılmış görüntüleri sınıflandırma sonuçlarında kabul edilebilir değerler vermişlerdir. Benzer şekilde Brovey ve Multiplicative kaynaştırılmış görüntüleri SAM ve SID metriklerinden başarılı sonuçlar alırken bu kaynaştırılmış görüntülerin sınıflandırma performansları bu metriklerin yanıltıcı olabileceğini göstermektedir. Çünkü bu kaynaştırılmış görüntüler sınıflandırma performansları bakımından başarısız olmuşlardır. HPF görüntü kaynaştırma yöntemi kaynaştırmadan sonra uyguladığı lineer germe işlemiyle spektral yapının korunmasını sağlarken, Kriter Tabanlı Görüntü Kaynaştırma yöntemi kullandığı kriterler sayesinde kaynaştırmada kullanılan çok bantlı görüntünün spektral yapısını korumayı başarmıştır. Bu iki kaynaştırma yöntemi farklı sensörlerden alınan görüntülerin kaynaştırılmasında da oldukça iyi metrik ve sınıflandırma sonuçları vermişlerdir. Her iki yöntemde de uygulanan filtrelerin yapısı değiştirilerek her iki görüntünün de konumsal detay kalitesi artırılabilir ancak bu durumda da spektral distorsiyonlar ortaya çıkabilmektedir. Bu iki yöntem de kaynaştırılmış görüntülerin bant ortalamalarının ve standart sapma değerlerinin orijinal çok bantlı görüntüyle aynı olmasını sağlamanın yanı sıra kaynaştırmada kullanılan çok bantlı görüntünün bantları arasındaki korelasyon dengesini de kaynaştırılmış görüntüye aktarmayı başarmışlardır.

4. SONUÇLAR VE ÖNERİLER

Görüntü kaynaştırma ile elde edilen kaynaştırılmış görüntülerin spektral kalitelerinin kontrolünü sağlayan bazı metrikler bulunmaktadır. Bu metriklerin dezavantajları 1.5.4 bölümünde anlatılmıştır. Sözü edilen metriklerin dezavantajlarından dolayı kaynaştırılmış görüntülerin sınıflandırma performanslarının irdelenmesi spektral kalitenin kontrolü açısından mantıklı bir yaklaşım olacaktır. Bu amaçla seçilen pilot bölgelere ait Worldview-2, Landsat ETM+ ve Ikonos görüntüleri kendi pankromatik bantlarıyla, başka bir Ikonos görüntüsü ise Quickbird pan-sharpened görüntüsünden elde edilen pankromatik görüntüyle kaynaştırılmıştır. Görüntüler kaynaştırılırken 11 farklı görüntü kaynaştırma yönteminden faydalanılmıştır. Bu yöntemler, CN, IHS, Gram-Schmidt, Dalgacık Dönüşümü, PCA, HPF, Ehlers, Brovey, Multiplicative, Kriter Tabanlı Görüntü Kaynaştırma yöntemi ve literatürdeki yeni bir yöntemdir. Kaynaştırılan görüntülerin spektral ve konumsal kalitelerinin kontrolü amacıyla kaynaştırılmış görüntüler için RASE, SID, Konumsal RMSE, Konumsal ERGAS, Spektral ERGAS, Spektral RMSE ve SAM metrikleri hesaplanmıştır. Elde edilen kaynaştırılmış görüntüler tamamen aynı imzalar kullanılarak 6 farklı sınıflandırma algoritmasına göre kontrollü sınıflandırılmıştır. Bu sınıflandırma algoritmaları Maksimum Benzerlik, Yapay Sinir Ağları, Destek Vektör Makineleri, En Yakın Mesafe, İkili Kodlama ve Rastgele Orman sınıflandırma algoritmalarıdır. Sınıflandırma işlemlerinde Ikonos, Landsat ETM+ ve Ikonos – QBPan veri setlerinden elde edilen kaynaştırılmış görüntüler 4, Worldview-2 veri setinden elde edilen kaynaştırılmış görüntüler 9 sınıfa ayrılmıştır. Sınıflandırma işlemlerinin genel doğrulukları her bir kaynaştırılmış görüntü için kullanılan 450 adet referans noktası ile belirlenmiştir. Hesaplanan metriklerle sınıflandırma doğrulukları birlikte incelenerek değerlendirilmiştir.

Şekil 18, Şekil 19, Şekil 20 ve Şekil 21’ de sırasıyla Worldview-2, Landsat ETM+, Ikonos ve Ikonos – QBPan veri setlerinden elde edilen kaynaştırılmış görüntülerin genel sınıflandırma doğrulukları gösterilmiştir. HPF görüntü kaynaştırma yöntemi sınıflandırma sonuçları itibariyle bu veri setleri için en başarılı kaynaştırma yöntemi olmuştur. Bütün kaynaştırma yöntemleri içerisinde ortalama genel sınıflandırma doğrulukları en yüksek olan kaynaştırma yöntemi HPF kaynaştırma yöntemidir. Worldview-2, Landsat ETM+, Ikonos ve Ikonos – QBPan veri setlerinden HPF kaynaştırma yöntemi ile elde edilen kaynaştırılmış görüntüler bu çalışma kapsamındaki bütün sınıflandırma yöntemleri ile

sınıflandırıldığında sırasıyla % 67, % 86, % 82 ve % 82 ortalama genel doğruluklarını vermiştir. Ehlers, Wavelet ve Kriter Tabanlı Görüntü Kaynaştırma yöntemleri Ikonos kaynaştırılmış görüntüleri için % 79 ortalama genel doğruluklar ile en iyi ikinci kaynaştırma yöntemleri olurken Kriter Tabanlı Görüntü Kaynaştırma yöntemi Landsat ETM+ kaynaştırılmış görüntüsü için % 84 ortalama genel doğruluk ile en iyi ikinci kaynaştırma yöntemi ve Yeni Yöntem ise Worldview-2 kaynaştırılmış görüntüsü için % 67 ile en iyi ikinci kaynaştırma yöntemi olmuştur. Ikonos ve Quickbird görüntülerinin kaynaştırılmasıyla elde edilen kaynaştırılmış görüntüler için en iyi ikinci kaynaştırma yöntemi ortalama % 80 genel doğrulukla Gram-Schmidt kaynaştırma yöntemi olmuştur. Brovey yöntemi % 61 ortalama genel doğruluk ile Ikonos kaynaştırılmış görüntüleri için en kötü kaynaştırma yöntemi olurken, IHS kaynaştırma yöntemi sırasıyla % 72 ve % 45 ortalama genel sınıflandırma doğrulukları ile Landsat ETM+ ve Worldview-2 kaynaştırılmış görüntüleri için en kötü sınıflandırma sonucu veren kaynaştırma yöntemi olmuştur. Destek Vektör Makineleri sınıflandırma yöntemi her dört veri seti için de en başarılı ortalama sınıflandırma sonucunu veren sınıflandırma yöntemi olmuştur. Destek Vektör Makineleri yönteminden sonra en yüksek ortalama sınıflandırma doğruluklarını veren sınıflandırma yöntemi Yapay Sinir Ağları sınıflandırma yöntemidir. Yapay Sinir Ağları yöntemi Worldview-2, Landsat ETM+, Ikonos ve Ikonos - QBPan veri setlerinden elde edilen kaynaştırılmış görüntülerde sırasıyla % 66, % 87, % 77 ve % 75 ortalama genel sınıflandırma doğruluklarını göstermiştir.

Worldview-2, Landsat ETM+, Ikonos ve Ikonos – Quickbird veri setlerinin kaynaştırılmasıyla elde edilen kaynaştırılmış görüntülerin radyometrik yapılarının kaynaştırmada kullanılan orijinal çok bantlı görüntü ile uyumluluklarının kıyaslanması amacıyla kaynaştırılan görüntülerin bantlarına ait ortalama değerleri hesaplanmıştır. Elde edilen sonuçlar Tablo 2, Tablo 3, Tablo 4 ve Tablo 5’ de gösterilmiştir. Bu şekillere göre HPF ve Kriter Tabanlı Görüntü Kaynaştırma yöntemleri çok bantlı görüntünün bantlarının ortalama değerlerini başarıyla korumaktadır. Yine aynı tablolarda kaynaştırılmış görüntülerinin bantlarının standart sapma değerleri görülmektedir. Bu değerlere göre HPF, Dalgacık Dönüşümü ve Kriter Tabanlı Görüntü Kaynaştırma yöntemleri çok bantlı görüntünün bantlarına ait standart sapma değerlerini korumaktadırlar. Orijinal görüntülerin bantları ile Worldview-2, Landsat ETM+, Ikonos ve Ikonos – QBPan veri setlerinden elde edilen kaynaştırılmış görüntülerin bantları arasındaki korelasyon değerleri Tablo 6, Tablo 7, Tablo 8 ve Tablo 9’ da gösterilmiştir. Buna göre orijinal görüntü ile arasında en yüksek

korelasyon bulunan kaynaştırılmış görüntü Worldview-2 ve Landsat ETM+ kaynaştırılmış görüntüleri için HPF kaynaştırma yöntemiyle elde edilen görüntüdür. HPF kaynaştırılmış görüntüsü ile orijinal Worlview-2 çok bantlı görüntüsü arasında ortalama % 96 korelasyon bulunmaktayken, HPF kaynaştırılmış görüntüsü ile orijinal çok bantlı Landsat ETM+ görüntüsü arasında ortalama % 94 korelasyon bulunmaktadır. Kriter Tabanlı Görüntü Kaynaştırma yöntemi ile Ikonos veri setlerinden elde edilen kaynaştırılmış görüntü ile orijinal çok bantlı Ikonos görüntüsü arasında ortalama % 84 korelasyon bulunmaktadır. Kriter Tabanlı Görüntü Kaynaştırma yöntemi ile Ikonos – QBPan veri setlerinden elde edilen kaynaştırılmış görüntü ile orijinal çok bantlı Ikonos görüntüsü arasında ise ortalama % 79 korelasyon bulunmaktadır. Orijinal çok bantlı görüntülerin bantları arasındaki korelasyon değerlerinin kaynaştırılan görüntülerin bantları arasındaki korelasyon değerlerine yakın olmasını sağlayan kaynaştırma yöntemleri başarılı kabul edilir. Ek Tablo 1, Ek Tablo 2, Ek Tablo 3 ve Ek Tablo 4’ de sırasıyla Worldview-2, Landsat ETM+, Ikonos ve Ikonos – QBPan veri setlerinden elde edilen kaynaştırılmış görüntülerinin bantları arasındaki iç korelasyon değerleri gösterilmiştir. Bu sonuçlara göre bantlarının korelasyonları orijinal görüntünün bantları arasındaki korelasyona en yakın olan görüntülerin, yani bantlar arasındaki ilişkiyi en iyi koruyan kaynaştırma yöntemlerinin Worldview-2 kaynaştırılmış görüntüleri için HPF, Kriter Tabanlı Görüntü Kaynaştırma yöntemi ve Yeni Yöntem, Landsat ETM+ kaynaştırılmış görüntüleri için HPF, Dalgacık Dönüşümü ve Kriter Tabanlı Görüntü Kaynaştırma yöntemi, Ikonos kaynaştırılmış görüntüleri için yine Kriter Tabanlı Görüntü Kaynaştırma yöntemi ve Ikonos – QBPan kaynaştırılmış görüntüleri için Gram-Schmidt kaynaştırma yöntemi olduğu görülmektedir. Kriter Tabanlı Görüntü Kaynaştırma yöntemi görüldüğü üzere bantlar arasındaki iç dengeyi korumada oldukça başarılıdır.

Tablo 10, Tablo 11, Tablo 12 ve Tablo 13’ de Worldview-2, Landsat ETM+, Ikonos ve Ikonos – QBPan veri setlerinden elde edilen kaynaştırılmış görüntülere ait metrik değerleri bulunmaktadır. Tablolar incelendiğinde HPF ve Kriter Tabanlı Görüntü Kaynaştırma yöntemlerinin çok bantlı görüntüdeki konumsal detayı kaynaştırılmış görüntüye aktarırken spektral yapıyı da başarılı bir şekilde korudukları görülmektedir. Kriter Tabanlı Görüntü Kaynaştırma yöntemi yüksek konumsal çözünürlüklü görüntülerin kaynaştırılmasında daha başarılı sonuçlar vermiştir. CN yöntemi spektral yapıyı bozmakla beraber konumsal detay aktarımında oldukça başarılıdır.

Bütün sınıflandırma sonuçları, istatistiki veriler ve metrik değerleri bir arada incelendiğinde HPF görüntü kaynaştırma yönteminin bu veri setlerinden elde edilen kaynaştırılmış görüntülerin spektral yapılarına en az zarar veren yöntem olduğu belirlenmiştir. HPF yöntemini Kriter Tabanlı Görüntü Kaynaştırma yöntemi izlemektedir. Bu iki yöntem de görüntüdeki spektral yapıyı mümkün olduğunca fazla korumaktadır. Bu yöntemlerle elde edilen kaynaştırılmış görüntülerin sınıflandırılmalarıyla tatmin edici sonuçlar alınmıştır.

HPF yöntemi bu çalışma kapsamında sınıflandırma performansını en fazla arttıran yöntem olarak belirlenmiştir. HPF yöntemi spektral yapıyı korumada başarılı bir yöntem olmasına rağmen renk yapısını belli bir oranda bozmaktadır. HPF yönteminin başarısı kullanılan filtre ile oldukça ilgilidir. Dolayısıyla HPF yöntemi kullanılan filtre geliştirilerek spektral yapıyı korumada daha da başarılı hale getirilebilir.

Kaynaştırılmış görüntülerin kalitelerinin değerlendirilmesi amacıyla kullanılan metriklerin bazılarının sınıflandırma sonuçları ile tutarsız olduğu görülmektedir. Örneğin Brovey ve Multiplicative kaynaştırma yöntemleri ile elde edilen kaynaştırılmış görüntüler spektral kaliteyi ölçen SID ve SAM metriklerinde oldukça iyi sonuçlar vermelerine rağmen sınıflandırma işlemlerinde kötü performans göstermişlerdir. Kaynaştırılan görüntülerin kalitelerinin değerlendirilmesi amacıyla kullanılan metrikler geliştirilmeli ve sınıflandırma sonuçları ile daha tutarlı metrikler tanıtılmalıdır.

5. KAYNAKLAR

- Abas, A., İ., 2011, Çok Spektrallı Görüntü Füzyonu, Yüksek Lisans Tezi, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Konya.
- Akça, M. D. ve Doğan, S., 2002. Sayısal Görüntülerde Ana Bileşenler Dönüşümü, Harita Dergisi, 129, 1-15.
- Alparone, L., Baronti, S., Garzelli, A. and Nencini, F., 2004. A Global Quality Measurement of Pan-Sharpned Multispectral Imagery. IEEE Geoscience and Remote Sensing Letters, 1, 4, 313-317.
- Armenakis, C., Leduc, F., Cyr, I., Savapol, F. and Cavayas, F., 2003. A Comparative Analysis of Scanned Maps and Imagery for Mapping Applications, ISPRS Journal of Photogrammetry & Remote Sensing, 57, 5, 304– 314.
- Ayhan, E., Karşlı, F. ve Tunç E., 2003. Uzaktan Algılanmış Görüntülerde Sınıflandırma ve Analiz, Harita Dergisi, 130, 32-46.
- Breiman, L., 1996. Bagging Predictors, *Machine Learning*, 24, 123–140.
- Breiman, L., 2001. Random Forests, *Machine Learning*, 45, 1-32.
- Breiman, L., Friedman, J. H., Olshen, R. A. and Stone, C. J., 1984. Classification and Regression Trees, Monterey, CA: Wadsworth.
- Brown, A. and Feringa, W., 2003. Colour Basics for GIS Users, Pearson Education Limited, ISBN: 0130333433.
- Canga, E., F., 2002. Image Fusion, Project Report for the Degree of MEng, Department of Electronic and Electrical Engineering, University of Bath.
- Chavez, P. S. and Bowell, J. A., 1988. Comparison of the Spectral Information Content of Landsat Thematic Mapper and SPOT for Three Different Sites in the Phoenix, Arizona Region, Photogrammetric Engineering and Remote Sensing. 55, 3, 339-348.
- Cramer, K. and Singer, Y., 2001. On the Algorithmic Implementation of Multiclass Kernel-Based Vector Machines, Journal of Machine Learning Research, 2, 265-292.
- Çelik, H., 2006. İstanbul Sarıyer İlçesine Ait Uzaktan Algılama Uydu Verileri ile Mekansal Veri Analizleri, Yüksek Lisans Tezi, On Sekiz Mart Üniversitesi, Fen Bilimleri Enstitüsü, Çanakkale.
- Çölkesen, İ., 2009. Uzaktan Algılamada İleri Sınıflandırma Tekniklerinin Karşılaştırılması ve Analizi, Yüksek Lisans Tezi, Gebze Yüksek Teknoloji Enstitüsü, Gebze.

- Çölova, İ. M., 2010. An FPGA Implementation of Real-Time Electro-Optic & IR Image Fusion, Master Thesis, Middle East Technical University, Ankara.
- Dammavalam, S. R., Maddala, S. and Mhm, K. P., 2012. Quality Assessment of Pixel-Level Image Fusion Using Fuzzy Logic, International Journal on Soft Computing, 3, 1, 11-23.
- Demir, B. ve Ertürk, S., 2007. Hiperspektral Görüntülerde Destek Vektör Makineleri ile Sınıflandırma Öncesi Dalgacık Uzayında Gürültü Giderimi, IEEE 15. Sinyal İşleme ve İletişim Uygulamaları Kurultayı.
- Ehlers, M., 2005. Beyond Pan Sharpening: Advances in Data Fusion for Very High Resolution Remote Sensing Data, ISPRS Hannover Workshop 'High Resolution Earth Imaging for Geospatial Information', 6.
- ENVI Online Help.
- Erdas Imagine Field Guide.
- Erdas Imagine Online Documents.
- Gangkofner, U. G. and Holcomb, D., 2008. "HP Resolution Merge," In: ERDAS IMAGINE Help, Leica Geosystems Geospatial Imaging, LLC.
- Gonzales, R. C. and Woods, R. E., 2003. Digital Image Processing, 2nd Edition, Pearson Education (Singapore) Pte. Ltd., Indian Branch, Delhi, India, ISBN: 8178086298.
- Gonzalo-Martin, C. and Lillo-Saavedra, M., 2011. Balancing the Spatial and Spectral Quality of Satellite Fused Images through a Search Algorithm, Search Algorithms and Applications, ISBN: 978-953-307-156-5, 117-132.
- Gungor, O., 2008. Multi Sensor Multi Resolution Image Fusion, Phd Thesis, Purdue University, Indiana, USA.
- Güngör, O., 2008. Kriter Tabanlı Görüntü Kaynaştırma Yöntemi.
- Harrison, B.A. and Jupp, D. L. B., 1990. Introduction to Image Processing CSIRO Publications, Canberra, Australia, ISBN 10: 0643050922.
- Kansu, O., 2006. Uzaktan Algılamada Görüntü Sınıflandırma Yöntemleri Analizi, Yüksek Lisans Tezi, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Trabzon.
- Klonus, S. and Ehlers, M., 2009. Performance of Evaluation Methods in Image Fusion, 12th International Conference on Information Fusion, Seattle, WA, USA, July 6-9, 1409-1416.
- Knerr, S., Personnaz, L. and Dreyfus, G., 1990. Single-Layer Learning Revisited: A Stepwise Procedure for Building and Training a Neural Network. Neurocomputing: Algorithms, Architectures and Applications. Springer-Verlag.

- Koç, A. ve Yener, H., 2001. Uzaktan Algılama Verileriyle İstanbul Çevresi Ormanlarının Alansal ve Yapısal Değişikliklerinin Saptanması, D.Ü. Orman Fakültesi Dergisi, 51, 2, 17-33.
- Kumar, U., Dasgupta, A., Mukhopadhyay, C., Joshi, N. V. and Ramachandra, T. V., 2011. Comparison of 10 Multi-Sensor Image Fusion Paradigms for IKONOS Images, International Journal of Research and Reviews in Computer Science, 2, 1, 40-47.
- Laben, C. A. and Brower, B. V., 2000. "Process for enhancing the spatial resolution of multispectral imagery using pan-sharpening," United States Eastman Kodak Company (Rochester, NY). US Patent 6011875.
- Lee, Y., Lin, Y. and Wahba, G., 2001. Multicategory support vector machines Tech. Rep. 1043, Department of Statistics, University of Wisconsin, Madison, WI.
- Lillo-Saavedra, M., Gonzalo, C., Arquero, A. and Martinez, E., 2005. Fusion of Multispectral and Panchromatic Satellite Sensor Imagery Based on Tailored Filtering in The Fourier Domain, International Journal of Remote Sensing, 26, 6, 1263–1268.
- Liu, Y. and Zheng, Y. F., 2005. One-Against-All Multi-Class SVM Classification Using Reliability Measures, International Joint Conference on Neural Networks, 2, 849-854.
- Mather, P. M., 1999. Computer Processing of Remotely-Sensed Images: An Introduction, 2nd Edition. John Wiley and Sons Ltd., ISBN: 0471985503.
- Mathur, A. and Foody, G. M., 2008a. Multiclass and binary SVM classification: Implications for training and classification users. IEEE Geoscience and Remote Sensing Letters 5, 241-245.
- Nunez, J., X., Fors, O., Prades, A., Pala, V. and Arbiol, R., 1999. Multiresolution-Based Image Fusion with Additive Wavelet Decomposition, IEEE Transactions on Geoscience and Remote Sensing, 37, 3, 1204-1211.
- Osuna, E. E., Freund, R. and Girosi, F., 1997. Support vector machines: training and applications, Massachusetts Institute of Technology Artificial Intelligence Laboratory and Center for Biological and Computational Learning Department of Brain and Cognitive Sciences, C.B.C.L. Paper No. 144, A. I. Memo No. 1602.
- Pal, M., 2005a. Multiclass approaches for support vector machine based land cover classification, In Proceedings of Map India, 8th Annual International Conference and Exhibition in the Field of GIS, GPS, Aerial Photography and Remote Sensing, New Delhi.
- Pal, M., 2005b. Random Forest Classifier for Remote Sensing Classification, International Journal of Remote Sensing, 26, 217-222.
- Petrou, M. and Bosdogianni, P., 1999. Image Processing: The Fundamentals, John Wiley and Sons. Ltd., ISBN: 0471998834.

- Pohl, C., 1997. Tools and Methods Used in Data Fusion, In Proceedings of The 17th EARSeL Symposium on Future Trends in Remote Sensing, pp. 391-399.
- Quinlan, J. R., 1993. C4.5: Programs for Machine Learning. Morgan Kaufmann Publishers, San Mateo, CA.
- Rumelhart, D. E., Hinton, G. E. and Williams, R. J., 1986. Learning Internal Representations by Error Propagation, Parallel Distributed Processing: Explorations in the Microstruction of Cognition, Rumelhart D. E. and McClelland, J. L.(Eds.), Cambridge, MA, The MIT Press. I: 318-362.
- Saroğlu, E., Bektaş, F., Musaoğlu, N. ve Göksel, C., 2004. Fusion of Multisensor Remote Sensing Data: Assessing the Quality of Resulting Images, XXth ISPRS Congress, Commission IV Papers, XXXV (part B4): p.575ff.
- Schölkopf, B. and Smola, A. J., 2002. Learning with Kernels – Support Vector Machines, Regularization, Optimization and Beyond, Cambridge, MA: The MIT Press.
- Schowengerdt, R. A., 2007. Remote Sensing: Models and Methods for Image Processing, Third Edition, ISBN 10: 0-12-369407-8, ISBN 13: 978-0-12-369407-2.
- Shamshad, A., Wan Hussin, W. M. A. and Mohd Sanusi, S. A., 2004. Comparison of Different Data Fusion Approaches for Surface Features Extraction Using Quickbird Images, International Symposium on Geoinformatics for Spatial Infrastructure Development in Earth and Allied Sciences, Hanoi, Vietnam, September, 16-18.
- Strait, M., Rahmani, S. and Markurjev, D., 2008. Evaluation of Pan-Sharpning Methods.
- Sunar, F. ve Kaya, Ş., 1996. Uydu Görüntülerinin Rektifikasyonu ve Analizi, İnşaat Mühendisliğinde Bilgisayar Kullanımı V. Sempozyumu, 17-19 Haziran, İTÜ, İstanbul.
- Tarhan, Ç., 2004. Planlamada Uzaktan Algılama ve Coğrafi Bilgi Sistemi Disiplinleri Entegrasyonu: Urla ve Balçova Örnekleri, Planlama Dergisi, ISSN 1300-7319, 29, 106-112.
- Tso, A. and Mather, P. M., 2009. Classification Methods for Remotely Sensed Data, Second Edition, ISBN: 978-1-4200-9072-7.
- Vapnik, V. N., 2000. The Nature of Statistical Learning Theory, Second Edition. Springer-Verlag, New York.
- Wald, L., 2002. Fusion of Images of Different Spatial Resolutions, Presses de l'Ecole, Ecole des Mines de Paris, Paris, France, ISBN: 2-911762-38-X, 200 pp.
- Welch, R. and Usery, L. E., 1984. Cartographic Accuracy of Landsat 4 MSS and TM Image Data, IEEE, Transaction on Geoscience and Remote Sensing, 22, 3.

Weston, J. and Watkins, C., 1998. Multi-class Support Vector Machines. Royal Holloway, University of London, U. K., Technical Report CSD-TR-98-04.

Yıldırım, D. ve Güngör, O., 2012. IKONOS Uydu Görüntüleri ile Yeni Bir Görüntü Kaynaştırma Yöntemi, Jeodezi ve Jeoinformasyon Dergisi, 1, 1, 75-83.

Yomralıođlu, T., 2005. Cođrafi Bilgi Sistemleri, 3. Baskı, İBER Ofset, Trabzon, ISBN: 975-97369-0-X.

URL-1, www.wikipedia.org, 15 Ekim 2012.

URL-2, http://landsat.usgs.gov/level_1G_1Gt_1T_Gap_filled_processing.php.

URL-3, http://paulbourke.net/texture_colour/equalisation/, 12 Ekim 2012.

URL-4, <http://www.turkiye-rehberi.net/trabzon-haritasi.asp>. 19 Eylül 2012.

URL-5, www.nik.com.tr, 10 Kasım 2012.

EKLER

Ek Tablo 1. Worldview-2 - Worldview-2 Pan kaynaştırılmış görüntüleri - iç korelasyonlar

		B1	B2	B3	B4	B5	B6	B7	B8
Orijinal	B1	1,000	0,957	0,899	0,827	0,769	-0,325	-0,512	-0,510
	B2	0,957	1,000	0,941	0,784	0,782	-0,356	-0,527	-0,534
	B3	0,899	0,941	1,000	0,851	0,850	-0,098	-0,281	-0,301
	B4	0,899	0,784	0,851	1,000	0,936	0,145	-0,099	-0,092
	B5	0,769	0,782	0,850	0,936	1,000	0,134	-0,084	-0,090
	B6	-0,325	-0,356	-0,098	0,145	0,134	1,000	0,931	0,945
	B7	-0,512	-0,527	-0,281	-0,099	-0,084	0,931	1,000	0,964
	B8	-0,510	-0,534	-0,301	-0,092	-0,090	0,945	0,964	1,000
Gram-Schmidt	B1	1,000	0,951	0,887	0,833	0,759	-0,076	-0,299	-0,303
	B2	0,951	1,000	0,936	0,804	0,783	-0,078	-0,289	-0,300
	B3	0,887	0,936	1,000	0,871	0,862	0,194	-0,014	-0,040
	B4	0,887	0,804	0,871	1,000	0,943	0,376	0,118	0,120
	B5	0,759	0,783	0,862	0,943	1,000	0,405	0,173	0,165
	B6	-0,076	-0,078	0,194	0,376	0,405	1,000	0,920	0,931
	B7	-0,299	-0,289	-0,014	0,118	0,173	0,920	1,000	0,956
	B8	-0,303	-0,300	-0,040	0,120	0,165	0,931	0,956	1,000
Yeni Yöntem	B1	1,000	0,959	0,910	0,825	0,763	-0,386	-0,566	-0,564
	B2	0,959	1,000	0,948	0,782	0,773	-0,421	-0,586	-0,592
	B3	0,910	0,948	1,000	0,845	0,840	-0,196	-0,374	-0,393
	B4	0,910	0,782	0,845	1,000	0,934	0,089	-0,153	-0,146
	B5	0,763	0,773	0,840	0,934	1,000	0,089	-0,126	-0,134
	B6	-0,386	-0,421	-0,196	0,089	0,089	1,000	0,932	0,946
	B7	-0,566	-0,586	-0,374	-0,153	-0,126	0,932	1,000	0,964
	B8	-0,564	-0,592	-0,393	-0,146	-0,134	0,946	0,964	1,000
Dalgacık Dönüşümü	B1	1,000	0,974	0,936	0,874	0,835	0,011	-0,132	-0,140
	B2	0,974	1,000	0,959	0,846	0,838	-0,005	-0,137	-0,149
	B3	0,936	0,959	1,000	0,900	0,892	0,201	0,060	0,043
	B4	0,936	0,846	0,900	1,000	0,961	0,370	0,191	0,189
	B5	0,835	0,838	0,892	0,961	1,000	0,368	0,203	0,194
	B6	0,011	-0,005	0,201	0,370	0,368	1,000	0,957	0,964
	B7	-0,132	-0,137	0,060	0,191	0,203	0,957	1,000	0,980
	B8	-0,140	-0,149	0,043	0,189	0,194	0,964	0,980	1,000

Ek Tablo 1' in devamı

CN	B1	1,000	0,974	0,926	0,792	0,731	-0,204	-0,382	-0,448
	B2	0,974	1,000	0,968	0,828	0,790	-0,200	-0,400	-0,455
	B3	0,926	0,968	1,000	0,886	0,859	-0,030	-0,252	-0,307
	B4	0,926	0,828	0,886	1,000	0,949	0,203	-0,086	-0,110
	B5	0,731	0,790	0,859	0,949	1,000	0,256	-0,014	-0,044
	B6	-0,204	-0,200	-0,030	0,203	0,256	1,000	0,913	0,921
	B7	-0,382	-0,400	-0,252	-0,086	-0,014	0,913	1,000	0,960
	B8	-0,448	-0,455	-0,307	-0,110	-0,044	0,921	0,960	1,000
Broyey	B1	1,000	0,974	0,932	0,813	0,743	-0,203	-0,438	-0,459
	B2	0,974	1,000	0,968	0,832	0,794	-0,203	-0,443	-0,464
	B3	0,932	0,968	1,000	0,886	0,861	-0,030	-0,283	-0,311
	B4	0,932	0,832	0,886	1,000	0,949	0,224	-0,086	-0,089
	B5	0,743	0,794	0,861	0,949	1,000	0,254	-0,033	-0,047
	B6	-0,203	-0,203	-0,030	0,224	0,254	1,000	0,909	0,921
	B7	-0,438	-0,443	-0,283	-0,086	-0,033	0,909	1,000	0,960
	B8	-0,459	-0,464	-0,311	-0,089	-0,047	0,921	0,960	1,000
Multiplicative	B1	1,000	0,953	0,946	0,921	0,864	0,789	0,610	0,606
	B2	0,953	1,000	0,979	0,946	0,933	0,679	0,479	0,468
	B3	0,946	0,979	1,000	0,946	0,939	0,696	0,500	0,483
	B4	0,946	0,946	0,946	1,000	0,933	0,609	0,369	0,367
	B5	0,864	0,933	0,939	0,933	1,000	0,547	0,324	0,309
	B6	0,789	0,679	0,696	0,609	0,547	1,000	0,932	0,941
	B7	0,610	0,479	0,500	0,369	0,324	0,932	1,000	0,972
	B8	0,606	0,468	0,483	0,367	0,309	0,941	0,972	1,000
PCA	B1	1,000	0,951	0,922	0,921	0,863	-0,044	-0,627	-0,661
	B2	0,951	1,000	0,971	0,886	0,886	-0,079	-0,615	-0,674
	B3	0,922	0,971	1,000	0,874	0,875	-0,014	-0,547	-0,650
	B4	0,922	0,886	0,874	1,000	0,936	0,123	-0,592	-0,620
	B5	0,863	0,886	0,875	0,936	1,000	0,083	-0,551	-0,618
	B6	-0,044	-0,079	-0,014	0,123	0,083	1,000	0,349	0,422
	B7	-0,627	-0,615	-0,547	-0,592	-0,551	0,349	1,000	0,690
	B8	-0,661	-0,674	-0,650	-0,620	-0,618	0,422	0,690	1,000

Ek Tablo 1' in devamı

Kriter Tab.	B1	1,000	0,956	0,897	0,799	0,755	-0,236	-0,398	-0,410
	B2	0,956	1,000	0,946	0,791	0,781	-0,301	-0,462	-0,477
	B3	0,897	0,946	1,000	0,860	0,846	-0,076	-0,254	-0,278
	B4	0,897	0,791	0,860	1,000	0,943	0,154	-0,085	-0,083
	B5	0,755	0,781	0,846	0,943	1,000	0,150	-0,067	-0,077
	B6	-0,236	-0,301	-0,076	0,154	0,150	1,000	0,935	0,946
	B7	-0,398	-0,462	-0,254	-0,085	-0,067	0,935	1,000	0,966
	B8	-0,410	-0,477	-0,278	-0,083	-0,077	0,946	0,966	1,000
HPF	B1	1,000	0,943	0,878	0,792	0,724	-0,242	-0,418	-0,417
	B2	0,943	1,000	0,938	0,778	0,766	-0,306	-0,475	-0,483
	B3	0,878	0,938	1,000	0,853	0,844	-0,048	-0,229	-0,250
	B4	0,878	0,778	0,853	1,000	0,935	0,184	-0,054	-0,049
	B5	0,724	0,766	0,844	0,935	1,000	0,177	-0,037	-0,044
	B6	-0,242	-0,306	-0,048	0,184	0,177	1,000	0,935	0,947
	B7	-0,418	-0,475	-0,229	-0,054	-0,037	0,935	1,000	0,965
	B8	-0,417	-0,483	-0,250	-0,049	-0,044	0,947	0,965	1,000
Ehlers	B1	1,000	0,946	0,876	0,811	0,750	-0,249	-0,455	-0,455
	B2	0,946	1,000	0,940	0,789	0,785	-0,313	-0,498	-0,506
	B3	0,876	0,940	1,000	0,854	0,852	-0,065	-0,259	-0,280
	B4	0,811	0,789	0,854	1,000	0,937	0,157	-0,086	-0,085
	B5	0,750	0,785	0,852	0,937	1,000	0,143	-0,072	-0,083
	B6	-0,249	-0,313	-0,065	0,157	0,143	1,000	0,931	0,944
	B7	-0,455	-0,498	-0,259	-0,086	-0,072	0,931	1,000	0,963
	B8	-0,455	-0,506	-0,280	-0,085	-0,083	0,944	0,963	1,000
IHS	B1	1,000	0,822	0,722					
	B2	0,822	1,000	0,935					
	B3	0,722	0,935	1,000					

Ek Tablo 2. Landsat ETM+ - Landsat ETM+ Pan kaynaştırılmış görüntüleri - iç korelasyonlar

		B1	B2	B3	B4	B5	B6
Orijinal	B1	1,000	0,513	0,607	-0,451	-0,246	0,097
	B2	0,513	1,000	0,957	0,476	0,655	0,851
	B3	0,607	0,957	1,000	0,343	0,555	0,802
	B4	-0,451	0,476	0,343	1,000	0,957	0,789
	B5	-0,246	0,655	0,555	0,957	1,000	0,923
	B6	0,097	0,851	0,802	0,789	0,923	1,000
Gram-Schmidt	B1	1,000	0,362	0,504	-0,603	-0,472	-0,155
	B2	0,362	1,000	0,938	0,462	0,596	0,801
	B3	0,504	0,938	1,000	0,284	0,449	0,716
	B4	-0,603	0,462	0,284	1,000	0,971	0,827
	B5	-0,472	0,596	0,449	0,971	1,000	0,926
	B6	-0,155	0,801	0,716	0,827	0,926	1,000
Yeni Yöntem	B1	1,000	-0,0977	-0,187	-0,7455	-0,7053	-0,6072
	B2	-0,0977	1,0000	0,9498	0,6304	0,7153	0,8212
	B3	-0,1866	0,9498	1,0000	0,6032	0,7116	0,8428
	B4	-0,7455	0,6304	0,6032	1,0000	0,9813	0,9203
	B5	-0,7053	0,7153	0,7116	0,9813	1,0000	0,9722
	B6	-0,6072	0,8212	0,8428	0,9203	0,9722	1,0000
Dalgacık D.	B1	1,000	0,497	0,599	-0,475	-0,274	0,071
	B2	0,497	1,000	0,955	0,470	0,649	0,848
	B3	0,599	0,955	1,000	0,329	0,541	0,793
	B4	-0,475	0,470	0,329	1,000	0,957	0,789
	B5	-0,274	0,649	0,541	0,957	1,000	0,923
	B6	0,071	0,848	0,793	0,789	0,923	1,000
CN	B1	1,000	0,984	0,915	0,915	0,917	0,831
	B2	0,984	1,000	0,950	0,911	0,945	0,884
	B3	0,915	0,950	1,000	0,771	0,899	0,942
	B4	0,915	0,911	0,771	1,000	0,923	0,734
	B5	0,917	0,945	0,899	0,923	1,000	0,923
	B6	0,831	0,884	0,942	0,734	0,923	1,000
IHS	B1	1,000	0,933	0,667			
	B2	0,933	1,000	0,635			
	B3	0,667	0,635	1,000			

Ek Tablo 2' nin devamı

Broye	B1	1,000	0,965	0,869	0,868	0,887	0,875
	B2	0,965	1,000	0,935	0,893	0,934	0,946
	B3	0,869	0,935	1,000	0,729	0,829	0,928
	B4	0,868	0,893	0,729	1,000	0,973	0,878
	B5	0,887	0,934	0,829	0,973	1,000	0,957
	B6	0,875	0,946	0,928	0,878	0,957	1,000
Multiplicative	B1	1,000	0,993	0,940	0,911	0,966	0,966
	B2	0,993	1,000	0,961	0,891	0,959	0,976
	B3	0,940	0,961	1,000	0,747	0,868	0,964
	B4	0,911	0,891	0,747	1,000	0,966	0,848
	B5	0,966	0,959	0,868	0,966	1,000	0,949
	B6	0,966	0,976	0,964	0,848	0,949	1,000
PCA	B1	1,000	0,728	0,772	-0,418	-0,093	0,360
	B2	0,728	1,000	0,954	0,221	0,531	0,822
	B3	0,772	0,954	1,000	0,110	0,460	0,804
	B4	-0,418	0,221	0,110	1,000	0,898	0,584
	B5	-0,093	0,531	0,460	0,898	1,000	0,861
	B6	0,360	0,822	0,804	0,584	0,861	1,000
Kriter Tab.	B1	1,000	0,582	0,598	-0,328	-0,164	0,135
	B2	0,582	1,000	0,954	0,494	0,654	0,844
	B3	0,598	0,954	1,000	0,375	0,571	0,811
	B4	-0,328	0,494	0,375	1,000	0,962	0,809
	B5	-0,164	0,654	0,571	0,962	1,000	0,930
	B6	0,135	0,844	0,811	0,809	0,930	1,000
HPF	B1	1,000	0,536	0,625	-0,352	-0,172	0,139
	B2	0,536	1,000	0,967	0,536	0,692	0,870
	B3	0,625	0,967	1,000	0,415	0,599	0,823
	B4	-0,352	0,536	0,415	1,000	0,965	0,823
	B5	-0,172	0,692	0,599	0,965	1,000	0,935
	B6	0,139	0,870	0,823	0,823	0,935	1,000
Ehlers	B1	1,000	0,597	0,532	-0,243	-0,151	0,044
	B2	0,597	1,000	0,916	0,531	0,642	0,767
	B3	0,532	0,916	1,000	0,397	0,579	0,796
	B4	-0,243	0,531	0,397	1,000	0,952	0,792
	B5	-0,151	0,642	0,579	0,952	1,000	0,924
	B6	0,044	0,767	0,796	0,792	0,924	1,000

Ek Tablo 3. İkonos - İkonos Pan kaynaştırılmış görüntüleri - iç korelasyonlar

		B1	B2	B3	B4
Orjinal	B1	1,000	0,981	0,919	0,855
	B2	0,981	1,000	0,965	0,913
	B3	0,919	0,965	1,000	0,960
	B4	0,855	0,913	0,960	1,000
Gram-S.	B1	1,000	0,980	0,918	0,855
	B2	0,980	1,000	0,965	0,914
	B3	0,918	0,965	1,000	0,961
	B4	0,855	0,914	0,961	1,000
Yeni Yönt.	B1	1,000	0,991	0,965	0,942
	B2	0,991	1,000	0,987	0,970
	B3	0,965	0,987	1,000	0,987
	B4	0,942	0,970	0,987	1,000
Dalgacık D.	B1	1,000	0,984	0,940	0,894
	B2	0,984	1,000	0,974	0,938
	B3	0,940	0,974	1,000	0,970
	B4	0,894	0,938	0,970	1,000
CN	B1	1,000	0,979	0,923	0,871
	B2	0,979	1,000	0,973	0,930
	B3	0,923	0,973	1,000	0,967
	B4	0,871	0,930	0,967	1,000
Broyey	B1	1,000	0,980	0,926	0,877
	B2	0,980	1,000	0,973	0,932
	B3	0,926	0,973	1,000	0,967
	B4	0,877	0,932	0,967	1,000

Ek Tablo 3' ün devamı

Multip.	B1	1,000	0,992	0,982	0,972
	B2	0,992	1,000	0,994	0,986
	B3	0,982	0,994	1,000	0,994
	B4	0,972	0,986	0,994	1,000
PCA	B1	1,000	0,985	0,936	0,885
	B2	0,985	1,000	0,973	0,932
	B3	0,936	0,973	1,000	0,968
	B4	0,885	0,932	0,968	1,000
Kriter Tab.	B1	1,000	0,973	0,910	0,851
	B2	0,973	1,000	0,967	0,919
	B3	0,910	0,967	1,000	0,964
	B4	0,851	0,919	0,964	1,000
HPF	B1	1,000	0,990	0,952	0,912
	B2	0,990	1,000	0,979	0,947
	B3	0,952	0,979	1,000	0,976
	B4	0,912	0,947	0,976	1,000
Ehlers	B1	1,000	0,960	0,872	0,832
	B2	0,960	1,000	0,958	0,914
	B3	0,872	0,958	1,000	0,953
	B4	0,832	0,914	0,953	1,000
IHS	B1	1,000	0,945	0,815	
	B2	0,945	1,000	0,941	
	B3	0,815	0,941	1,000	

Ek Tablo 4. İkonos - QBPan kaynaştırılmış görüntüleri - iç korelasyonlar

		B1	B2	B3	B4
Orjinal	B1	1,000	0,976	0,907	0,684
	B2	0,976	1,000	0,955	0,766
	B3	0,907	0,955	1,000	0,790
	B4	0,684	0,766	0,790	1,000
Gram-S.	B1	1,000	0,976	0,907	0,679
	B2	0,976	1,000	0,956	0,764
	B3	0,907	0,956	1,000	0,792
	B4	0,679	0,764	0,792	1,000
Yeni Yönt.	B1	1,000	0,974	0,933	0,858
	B2	0,974	1,000	0,978	0,893
	B3	0,933	0,978	1,000	0,894
	B4	0,858	0,893	0,894	1,000
Dalgacık D.	B1	1,000	0,979	0,929	0,761
	B2	0,979	1,000	0,966	0,827
	B3	0,929	0,966	1,000	0,845
	B4	0,761	0,827	0,845	1,000
CN	B1	1,000	0,949	0,781	0,598
	B2	0,949	1,000	0,917	0,729
	B3	0,781	0,917	1,000	0,778
	B4	0,598	0,729	0,778	1,000
Brovey	B1	1,000	0,949	0,785	0,610
	B2	0,949	1,000	0,920	0,739
	B3	0,785	0,920	1,000	0,784
	B4	0,610	0,739	0,784	1,000

Ek Tablo 4' ün devamı

Multip.	B1	1,000	0,991	0,959	0,902
	B2	0,991	1,000	0,982	0,925
	B3	0,959	0,982	1,000	0,931
	B4	0,902	0,925	0,931	1,000
PCA	B1	1,000	0,993	0,970	0,894
	B2	0,993	1,000	0,987	0,924
	B3	0,970	0,987	1,000	0,933
	B4	0,894	0,924	0,933	1,000
Kriter Tab.	B1	1,000	0,962	0,881	0,696
	B2	0,962	1,000	0,956	0,785
	B3	0,881	0,956	1,000	0,805
	B4	0,696	0,785	0,805	1,000
HPF	B1	1,000	0,988	0,947	0,797
	B2	0,988	1,000	0,975	0,848
	B3	0,947	0,975	1,000	0,860
	B4	0,797	0,848	0,860	1,000
Ehlers	B1	1,000	0,369	0,114	0,476
	B2	0,369	1,000	0,916	0,664
	B3	0,114	0,916	1,000	0,611
	B4	0,476	0,664	0,611	1,000
IHS	B1	1,000	0,881	0,701	
	B2	0,881	1,000	0,935	
	B3	0,701	0,935	1,000	

Ek Tablo 5. Orijinal görüntü ve Worldview-2 kaynaştırılmış görüntüleri için İkili Kodlama ile elde edilen kullanıcı ve üretici sınıflandırma doğrulukları

BE		Su	Yol	Fındık	Orman	Kayalık	Toprak	Çay	Bina	Gölge
Brovey	Kull. D.	94	28	37	48	71	58	27	53	67
	Üret. D.	81	57	49	36	51	57	52	31	52
CN	Kull. D.	81	33	41	36	77	56	33	47	67
	Üret. D.	80	50	55	29	55	51	50	29	54
Yeni Y.	Kull. D.	89	20	38	38	90	67	45	77	85
	Üret. D.	81	56	54	33	67	62	59	39	60
Ehlers	Kull. D.	83	30	36	43	81	58	43	90	79
	Üret. D.	78	78	54	36	54	55	67	42	57
Gram-S.	Kull. D.	78	17	33	40	6	22	25	3	15
	Üret. D.	70	50	34	25	6	25	35	2	20
HPF	Kull. D.	92	35	37	40	97	61	55	73	76
	Üret. D.	78	73	51	43	64	56	65	41	58
IHS	Kull. D.	0	0	0	0	0	0	0	0	0
	Üret. D.	0	0	0	0	0	0	0	0	0
Kriter T.	Kull. D.	95	30	47	41	55	56	45	47	48
	Üret. D.	79	42	55	41	44	38	61	45	44
Multip.	Kull. D.	91	15	38	43	58	75	29	53	76
	Üret. D.	77	54	49	35	46	60	42	31	61
PCA	Kull. D.	0	0	0	0	0	0	0	0	0
	Üret. D.	0	0	0	0	0	0	0	0	0
Wavelet	Kull. D.	84	41	32	36	74	58	20	90	70
	Üret. D.	73	83	46	30	55	50	40	42	58
Orijinal G.	Kull. D.	88	35	33	29	77	61	27	77	61
	Üret. D.	77	84	45	25	53	56	44	38	51

Ek Tablo 6. Orijinal görüntü ve Worldview-2 kaynaştırılmış görüntüleri için En Yakın Mesafe ile elde edilen kullanıcı ve üretici sınıflandırma doğrulukları

EYM		Su	Yol	Fındık	Orman	Kayalık	Toprak	Çay	Bina	Gölge
Brovey	Kull. D.	88	9	39	36	39	17	31	20	45
	Üret. D.	76	24	51	24	26	22	53	12	38
CN	Kull. D.	88	9	38	31	48	14	24	47	39
	Üret. D.	74	33	43	24	39	18	41	20	37
Yeni Y.	Kull. D.	92	35	31	33	84	58	39	40	70
	Üret. D.	76	64	44	31	54	55	51	25	55
Ehlers	Kull. D.	92	52	33	40	16	61	33	27	39
	Üret. D.	77	52	53	40	13	43	49	16	42
Gram-S.	Kull. D.	91	35	31	34	42	64	41	13	70
	Üret. D.	79	57	46	30	35	52	51	9	47
HPF	Kull. D.	88	20	40	52	52	42	29	57	67
	Üret. D.	84	45	53	37	48	45	45	30	45
IHS	Kull. D.	88	37	34	34	16	28	18	47	18
	Üret. D.	71	68	39	23	18	34	31	23	24
Kriter T.	Kull. D.	92	15	36	36	74	69	24	47	67
	Üret. D.	75	39	45	30	53	57	44	29	54
Multip.	Kull. D.	92	24	36	33	23	17	24	37	33
	Üret. D.	71	55	39	24	24	22	38	19	38
PCA	Kull. D.	89	26	37	24	29	22	29	53	39
	Üret. D.	78	67	42	19	28	25	38	28	38
Wavelet	Kull. D.	89	9	36	31	58	11	37	30	30
	Üret. D.	75	36	40	24	43	14	48	16	33
Orijinal G.	Kull. D.	80	9	38	29	35	6	14	7	15
	Üret. D.	68	24	40	19	30	8	24	4	19

Ek Tablo 7. Orijinal görüntü ve Worldview-2 kaynaştırılmış görüntüleri için Maksimum Benzerlik ile elde edilen kullanıcı ve üretici sınıflandırma doğrulukları

MB		Su	Yol	Fındık	Orman	Kayalık	Toprak	Çay	Bina	Gölge
Brovey	Kull. D.	84	50	57	48	71	44	35	73	76
	Üret. D.	93	79	59	41	58	52	56	41	61
CN	Kull. D.	88	48	54	53	90	78	55	43	94
	Üret. D.	93	61	69	47	70	67	68	33	67
Yeni Y.	Kull. D.	88	91	55	67	97	78	71	50	82
	Üret. D.	89	84	77	58	70	70	82	43	77
Ehlers	Kull. D.	92	63	51	64	68	89	71	67	94
	Üret. D.	83	85	77	57	62	74	78	43	70
Gram-S.	Kull. D.	84	70	53	62	90	75	71	63	88
	Üret. D.	92	78	74	57	70	68	78	42	67
HPF	Kull. D.	86	67	71	64	87	81	65	60	91
	Üret. D.	92	84	80	58	73	74	80	44	73
IHS	Kull. D.	89	28	51	40	52	47	35	27	76
	Üret. D.	81	59	56	34	44	47	45	18	61
Kriter T.	Kull. D.	84	72	61	69	87	92	76	30	88
	Üret. D.	81	79	77	61	71	80	80	32	76
Multip.	Kull. D.	81	41	51	53	68	39	29	63	64
	Üret. D.	83	73	57	40	58	45	48	34	55
PCA	Kull. D.	91	39	58	52	74	61	51	63	85
	Üret. D.	88	67	65	48	59	63	65	40	67
Wavelet	Kull. D.	88	63	50	66	97	89	65	73	91
	Üret. D.	98	78	71	58	70	74	79	45	70
Orijinal G.	Kull. D.	89	48	51	57	94	83	53	73	76
	Üret. D.	95	76	65	51	64	68	73	41	69

Ek Tablo 8. Orijinal görüntü ve Worldview-2 kaynaştırılmış görüntüleri için Yapay Sinir Ağları ile elde edilen kullanıcı ve üretici sınıflandırma doğrulukları

YSA		Su	Yol	Fındık	Orman	Kayalık	Toprak	Çay	Bina	Gölge
Brovey	Kull. D.	83	59	52	66	68	75	37	37	85
	Üret. D.	90	87	61	48	62	59	56	30	65
CN	Kull. D.	92	48	54	53	94	58	57	77	73
	Üret. D.	92	85	67	46	64	64	66	45	63
Yeni Y.	Kull. D.	91	61	70	59	81	78	71	80	76
	Üret. D.	94	93	72	55	71	72	80	56	69
Ehlers	Kull. D.	91	50	57	64	97	58	71	80	88
	Üret. D.	95	88	67	56	73	60	75	51	73
Gram-S.	Kull. D.	88	46	58	71	84	83	67	87	97
	Üret. D.	93	81	77	61	58	73	79	54	74
HPF	Kull. D.	88	59	55	81	94	83	80	77	97
	Üret. D.	98	79	81	64	76	79	82	50	73
IHS	Kull. D.	81	33	51	53	39	53	57	57	58
	Üret. D.	87	60	56	40	40	53	64	33	51
Kriter T.	Kull. D.	88	72	51	59	94	89	75	80	91
	Üret. D.	88	85	78	55	73	71	73	60	73
Multip.	Kull. D.	89	52	48	59	90	58	37	53	82
	Üret. D.	89	71	59	46	68	54	61	36	66
PCA	Kull. D.	86	46	55	57	84	69	63	67	73
	Üret. D.	89	68	68	49	70	68	70	41	62
Wavelet	Kull. D.	86	76	49	74	97	75	65	57	94
	Üret. D.	86	85	75	61	73	69	73	43	70
Orijinal G.	Kull. D.	86	41	51	57	94	69	61	80	82
	Üret. D.	96	76	66	46	67	68	72	43	66

Ek Tablo 9. Orijinal görüntü ve Worldview-2 kaynaştırılmış görüntüleri için Rastgele Orman ile elde edilen kullanıcı ve üretici sınıflandırma doğrulukları

RO		Su	Yol	Fındık	Orman	Kayalık	Toprak	Çay	Bina	Gölge
Brovey	Kull. D.	94	37	48	50	84	78	69	37	85
	Üret. D.	81	81	62	45	63	68	67	30	67
CN	Kull. D.	88	65	50	69	90	86	73	63	82
	Üret. D.	82	88	72	61	68	72	73	46	73
Yeni Y.	Kull. D.	88	72	53	72	97	78	73	93	91
	Üret. D.	84	92	79	65	77	74	79	56	75
Ehlers	Kull. D.	86	63	50	72	90	86	76	93	91
	Üret. D.	89	97	76	63	68	76	81	55	68
Gram-S.	Kull. D.	91	65	54	71	87	75	75	97	88
	Üret. D.	84	92	75	59	71	71	83	62	73
HPF	Kull. D.	92	63	55	71	94	92	73	93	88
	Üret. D.	87	94	81	66	76	75	79	55	73
IHS	Kull. D.	88	22	41	52	61	67	43	40	70
	Üret. D.	80	91	52	38	49	55	48	28	58
Kriter T.	Kull. D.	92	61	56	71	97	75	71	93	85
	Üret. D.	87	90	77	61	71	71	75	60	74
Multip.	Kull. D.	88	74	48	52	74	44	69	53	45
	Üret. D.	90	89	55	41	68	53	60	38	60
PCA	Kull. D.	86	39	51	52	84	81	49	60	94
	Üret. D.	98	86	61	43	63	66	61	38	69
Wavelet	Kull. D.	89	67	54	71	94	78	69	53	94
	Üret. D.	89	97	76	56	74	76	69	41	72
Orijinal G.	Kull. D.	88	54	62	55	90	69	63	50	91
	Üret. D.	98	96	68	48	76	74	50	42	81

Ek Tablo 10. Orijinal görüntü ve Worldview-2 kaynaştırılmış görüntüleri için Destek Vektör Makineleri ile elde edilen kullanıcı ve üretici sınıflandırma doğrulukları

DVM		Su	Yol	Fındık	Orman	Kayalık	Toprak	Çay	Bina	Gölge
Brovey	Kull. D.	92	48	44	55	71	75	51	70	67
	Üret. D.	86	52	68	47	43	51	68	43	63
CN	Kull. D.	77	74	55	62	77	89	78	83	76
	Üret. D.	83	70	76	52	59	74	83	53	71
Yeni Y.	Kull. D.	88	72	62	88	81	86	75	50	94
	Üret. D.	89	70	72	65	74	79	83	50	79
Ehlers	Kull. D.	81	72	68	81	68	81	67	77	55
	Üret. D.	88	89	76	53	72	81	77	59	69
Gram-S.	Kull. D.	89	72	54	76	97	81	78	80	79
	Üret. D.	85	70	81	66	83	73	78	69	67
HPF	Kull. D.	86	72	63	78	97	75	82	93	94
	Üret. D.	87	87	77	69	81	79	84	61	79
IHS	Kull. D.	95	46	43	52	58	53	53	57	70
	Üret. D.	82	95	56	39	53	58	52	40	61
Kriter T.	Kull. D.	92	65	61	76	90	92	73	60	91
	Üret. D.	88	71	85	69	74	77	77	49	60
Multip.	Kull. D.	83	65	36	59	97	19	67	90	88
	Üret. D.	80	69	51	44	73	35	65	54	66
PCA	Kull. D.	83	54	51	57	87	78	61	60	79
	Üret. D.	80	81	69	52	66	65	66	42	63
Wavelet	Kull. D.	89	57	59	59	90	92	76	83	85
	Üret. D.	84	84	78	59	72	75	78	56	74
Orijinal G.	Kull. D.	89	67	50	69	81	83	69	47	94
	Üret. D.	85	86	74	58	61	75	78	38	66

Ek Tablo 11. Orijinal görüntü ve Landsat ETM+ kaynaştırılmış görüntüleri için İkili Kodlama ile elde edilen kullanıcı ve üretici sınıflandırma doğrulukları

BE		Su	Orman	Kent	Toprak
Brovey	Kull. D.	82	59	46	57
	Üret. D.	64	75	44	53
CN	Kull. D.	86	59	66	57
	Üret. D.	65	78	53	65
Yeni Y.	Kull. D.	80	72	54	53
	Üret. D.	83	88	42	25
Ehlers	Kull. D.	83	62	73	57
	Üret. D.	67	79	56	68
Gram-S.	Kull. D.	86	62	78	37
	Üret. D.	67	81	56	55
HPF	Kull. D.	79	75	61	67
	Üret. D.	72	80	61	71
IHS	Kull. D.	76	59	46	23
	Üret. D.	67	69	35	27
Kriter T.	Kull. D.	83	75	59	70
	Üret. D.	73	82	62	72
Multip.	Kull. D.	86	65	39	40
	Üret. D.	72	75	37	46
PCA	Kull. D.	86	60	68	43
	Üret. D.	72	77	46	52
Wavelet	Kull. D.	84	62	61	50
	Üret. D.	71	77	45	48
Orijinal G.	Kull. D.	85	65	51	43
	Üret. D.	72	76	42	54

Ek Tablo 12. Orijinal görüntü ve Landsat ETM+ kaynaştırılmış görüntüleri için En Yakın Mesafe ile elde edilen kullanıcı ve üretici sınıflandırma doğrulukları

EYM		Su	Orman	Kent	Toprak
Brovey	Kull. D.	79	59	51	57
	Üret. D.	54	77	78	74
CN	Kull. D.	87	61	46	40
	Üret. D.	57	83	70	67
Yeni Y.	Kull. D.	80	68	59	60
	Üret. D.	79	87	44	28
Ehlers	Kull. D.	87	63	56	67
	Üret. D.	59	84	85	91
Gram-S.	Kull. D.	83	62	54	67
	Üret. D.	58	82	71	83
HPF	Kull. D.	87	63	61	77
	Üret. D.	61	83	86	88
IHS	Kull. D.	76	60	17	37
	Üret. D.	62	71	20	33
Kriter T.	Kull. D.	79	68	51	50
	Üret. D.	59	83	78	50
Multip.	Kull. D.	81	65	39	40
	Üret. D.	60	83	62	33
PCA	Kull. D.	81	64	37	37
	Üret. D.	65	77	38	37
Wavelet	Kull. D.	77	61	37	37
	Üret. D.	62	74	38	37
Orijinal G.	Kull. D.	82	65	37	57
	Üret. D.	66	80	43	47

Ek Tablo 13. Orijinal görüntü ve Landsat ETM+ kaynaştırılmış görüntüleri için Maksimum Benzerlik ile elde edilen kullanıcı ve üretici sınıflandırma doğrulukları

MB		Su	Orman	Kent	Toprak
Brovey	Kull. D.	86	80	83	83
	Üret. D.	75	89	87	81
CN	Kull. D.	87	85	85	83
	Üret. D.	81	90	88	86
Yeni Y.	Kull. D.	89	89	88	87
	Üret. D.	94	97	72	55
Ehlers	Kull. D.	87	88	85	77
	Üret. D.	83	90	83	82
Gram-S.	Kull. D.	93	89	76	77
	Üret. D.	86	93	82	77
HPF	Kull. D.	94	93	80	77
	Üret. D.	91	95	83	77
IHS	Kull. D.	82	84	59	70
	Üret. D.	75	85	77	70
Kriter T.	Kull. D.	89	88	88	83
	Üret. D.	85	92	88	83
Multip.	Kull. D.	88	83	71	80
	Üret. D.	78	89	83	83
PCA	Kull. D.	87	83	71	77
	Üret. D.	78	88	81	77
Wavelet	Kull. D.	90	92	71	80
	Üret. D.	89	91	83	75
Orijinal G.	Kull. D.	87	86	73	83
	Üret. D.	81	89	86	81

Ek Tablo 14. Orijinal görüntü ve Landsat ETM+ kaynaştırılmış görüntüleri için Yapay Sinir Ağları ile elde edilen kullanıcı ve üretici sınıflandırma doğrulukları

YSA		Su	Orman	Kent	Toprak
Brovey	Kull. D.	87	82	85	93
	Üret. D.	78	88	95	97
CN	Kull. D.	91	90	85	90
	Üret. D.	87	91	92	96
Yeni Y.	Kull. D.	95	95	83	83
	Üret. D.	92	97	89	74
Ehlers	Kull. D.	93	92	98	93
	Üret. D.	90	94	95	97
Gram-S.	Kull. D.	83	83	90	87
	Üret. D.	78	89	80	90
HPF	Kull. D.	97	96	88	77
	Üret. D.	90	98	95	92
IHS	Kull. D.	84	82	71	90
	Üret. D.	76	87	91	77
Kriter T.	Kull. D.	95	95	80	83
	Üret. D.	93	95	89	86
Multip.	Kull. D.	87	84	76	87
	Üret. D.	78	89	89	84
PCA	Kull. D.	87	83	83	83
	Üret. D.	78	90	87	83
Wavelet	Kull. D.	94	93	85	83
	Üret. D.	90	95	88	83
Orijinal G.	Kull. D.	91	91	80	73
	Üret. D.	88	93	80	76

Ek Tablo 15. Orijinal görüntü ve Landsat ETM+ kaynaştırılmış görüntüleri için Rastgele Orman ile elde edilen kullanıcı ve üretici sınıflandırma doğrulukları

RO		Su	Orman	Kent	Toprak
Brovey	Kull. D.	91	87	73	87
	Üret. D.	81	91	88	90
CN	Kull. D.	94	91	78	80
	Üret. D.	88	94	84	86
Yeni Y.	Kull. D.	93	90	88	87
	Üret. D.	93	95	82	68
Ehlers	Kull. D.	81	84	90	93
	Üret. D.	78	85	97	97
Gram-S.	Kull. D.	96	90	88	90
	Üret. D.	87	96	92	96
HPF	Kull. D.	97	94	88	90
	Üret. D.	92	97	92	90
IHS	Kull. D.	82	80	66	70
	Üret. D.	73	84	75	84
Kriter T.	Kull. D.	94	93	85	83
	Üret. D.	90	95	88	89
Multip.	Kull. D.	87	81	95	83
	Üret. D.	76	89	91	96
PCA	Kull. D.	87	84	85	73
	Üret. D.	78	89	85	96
Wavelet	Kull. D.	74	61	61	83
	Üret. D.	57	75	86	78
Orijinal G.	Kull. D.	92	88	83	87
	Üret. D.	83	92	89	93

Ek Tablo 16. Orijinal görüntü ve Landsat ETM+ kaynaştırılmış görüntüleri için Destek Vektör Makineleri ile elde edilen kullanıcı ve üretici sınıflandırma doğrulukları

DVM		Su	Orman	Kent	Toprak
Brovey	Kull. D.	86	87	98	80
	Üret. D.	99	94	65	53
CN	Kull. D.	85	91	98	97
	Üret. D.	98	95	70	67
Yeni Y.	Kull. D.	92	91	90	80
	Üret. D.	92	95	88	62
Ehlers	Kull. D.	96	94	88	83
	Üret. D.	99	100	72	64
Gram-S.	Kull. D.	91	96	90	97
	Üret. D.	99	99	80	69
HPF	Kull. D.	96	95	98	93
	Üret. D.	99	100	83	72
IHS	Kull. D.	80	75	90	80
	Üret. D.	99	92	49	37
Kriter T.	Kull. D.	92	95	88	87
	Üret. D.	91	94	95	87
Multip.	Kull. D.	87	84	93	87
	Üret. D.	97	96	59	50
PCA	Kull. D.	87	88	98	93
	Üret. D.	99	97	67	56
Wavelet	Kull. D.	96	94	80	80
	Üret. D.	92	97	87	75
Orijinal G.	Kull. D.	89	89	93	90
	Üret. D.	98	97	62	61

Ek Tablo 17. Orijinal görüntü ve İkonos kaynaştırılmış görüntüleri için İkili Kodlama ile elde edilen kullanıcı ve üretici sınıflandırma doğrulukları

BE		Gölge	Bina	Yeşil Alan	Yol
Brovey	Kull. D.	84	54	80	18
	Üret. D.	75	75	36	12
CN	Kull. D.	71	68	83	74
	Üret. D.	80	90	46	42
Yeni Y.	Kull. D.	82	66	83	70
	Üret. D.	78	91	44	42
Ehlers	Kull. D.	87	67	87	65
	Üret. D.	77	89	49	43
Gram-S.	Kull. D.	84	72	87	71
	Üret. D.	76	91	54	47
HPF	Kull. D.	90	72	80	59
	Üret. D.	79	89	52	43
IHS	Kull. D.	74	60	47	61
	Üret. D.	68	81	28	37
Kriter T.	Kull. D.	84	68	80	65
	Üret. D.	76	88	47	43
Multip.	Kull. D.	84	54	73	27
	Üret. D.	76	76	34	17
PCA	Kull. D.	79	52	73	33
	Üret. D.	74	76	32	20
Wavelet	Kull. D.	83	71	83	53
	Üret. D.	77	87	49	39
Orijinal G.	Kull. D.	86	71	70	55
	Üret. D.	75	87	45	40

Ek Tablo 18. Orijinal görüntü ve İkonos kaynaştırılmış görüntüleri için En Yakın Mesafe ile elde edilen kullanıcı ve üretici sınıflandırma doğrulukları

EYM		Gölge	Bina	Yeşil Alan	Yol
Brovey	Kull. D.	78	65	47	59
	Üret. D.	70	81	30	40
CN	Kull. D.	84	64	83	64
	Üret. D.	76	88	45	40
Yeni Y.	Kull. D.	87	66	80	67
	Üret. D.	71	89	51	43
Ehlers	Kull. D.	84	65	67	67
	Üret. D.	71	87	43	42
Gram-S.	Kull. D.	82	70	83	65
	Üret. D.	73	89	51	44
HPF	Kull. D.	86	70	83	62
	Üret. D.	74	89	49	45
IHS	Kull. D.	58	62	47	58
	Üret. D.	58	84	30	32
Kriter T.	Kull. D.	88	66	80	64
	Üret. D.	72	89	45	44
Multip.	Kull. D.	58	61	73	74
	Üret. D.	64	85	38	40
PCA	Kull. D.	64	62	77	74
	Üret. D.	67	86	40	41
Wavelet	Kull. D.	83	66	80	68
	Üret. D.	70	90	41	45
Orijinal G.	Kull. D.	81	64	77	64
	Üret. D.	69	88	40	42

Ek Tablo 19. Orijinal görüntü ve İkonos kaynaştırılmış görüntüleri için Maksimum Benzerlik ile elde edilen kullanıcı ve üretici sınıflandırma doğrulukları

MB		Gölge	Bina	Yeşil Alan	Yol
Brovey	Kull. D.	91	52	70	33
	Üret. D.	72	78	33	21
CN	Kull. D.	88	74	80	77
	Üret. D.	84	92	52	50
Yeni Y.	Kull. D.	91	79	87	77
	Üret. D.	80	94	67	56
Ehlers	Kull. D.	94	82	73	82
	Üret. D.	89	94	59	60
Gram-S.	Kull. D.	92	81	93	82
	Üret. D.	89	95	62	61
HPF	Kull. D.	86	85	90	82
	Üret. D.	85	93	71	68
IHS	Kull. D.	77	66	53	65
	Üret. D.	76	85	33	40
Kriter T.	Kull. D.	86	83	90	77
	Üret. D.	83	93	66	62
Multip.	Kull. D.	81	62	60	64
	Üret. D.	76	84	38	36
PCA	Kull. D.	84	64	67	64
	Üret. D.	77	86	44	37
Wavelet	Kull. D.	92	81	83	74
	Üret. D.	88	94	60	55
Orijinal G.	Kull. D.	91	73	80	77
	Üret. D.	85	95	49	48

Ek Tablo 20. Orijinal görüntü ve İkonos kaynaştırılmış görüntüleri için Yapay Sinir Ağları ile elde edilen kullanıcı ve üretici sınıflandırma doğrulukları

YSA		Gölge	Bina	Yeşil Alan	Yol
Brovey	Kull. D.	87	64	73	67
	Üret. D.	67	90	43	43
CN	Kull. D.	82	80	83	89
	Üret. D.	81	95	61	61
Yeni Y.	Kull. D.	79	65	57	76
	Üret. D.	73	90	32	45
Ehlers	Kull. D.	92	83	87	77
	Üret. D.	76	98	59	65
Gram-S.	Kull. D.	92	87	90	83
	Üret. D.	91	95	73	68
HPF	Kull. D.	92	87	93	83
	Üret. D.	89	96	74	67
IHS	Kull. D.	69	72	60	61
	Üret. D.	85	88	38	35
Kriter T.	Kull. D.	84	75	73	85
	Üret. D.	88	94	52	50
Multip.	Kull. D.	86	69	60	73
	Üret. D.	81	91	39	42
PCA	Kull. D.	78	73	53	73
	Üret. D.	79	89	38	46
Wavelet	Kull. D.	90	84	80	80
	Üret. D.	87	94	65	62
Orijinal G.	Kull. D.	90	78	87	82
	Üret. D.	88	94	59	55

Ek Tablo 21. Orijinal görüntü ve İkonos kaynaştırılmış görüntüleri için Rastgele Orman ile elde edilen kullanıcı ve üretici sınıflandırma doğrulukları

RO		Gölge	Bina	Yeşil Alan	Yol
Brovey	Kull. D.	81	55	80	38
	Üret. D.	73	79	34	25
CN	Kull. D.	97	78	83	71
	Üret. D.	81	92	61	57
Yeni Y.	Kull. D.	87	85	93	82
	Üret. D.	86	94	67	67
Ehlers	Kull. D.	94	86	87	71
	Üret. D.	87	93	70	63
Gram-S.	Kull. D.	90	86	80	85
	Üret. D.	90	93	67	70
HPF	Kull. D.	91	91	87	79
	Üret. D.	95	94	74	70
IHS	Kull. D.	79	67	47	53
	Üret. D.	71	83	34	36
Kriter T.	Kull. D.	88	86	90	82
	Üret. D.	88	95	69	64
Multip.	Kull. D.	71	62	70	56
	Üret. D.	71	82	39	34
PCA	Kull. D.	71	71	70	61
	Üret. D.	73	85	43	42
Wavelet	Kull. D.	86	83	87	85
	Üret. D.	89	95	63	60
Orijinal G.	Kull. D.	90	74	83	82
	Üret. D.	81	93	54	54

Ek Tablo 22. Orijinal görüntü ve İkonos kaynaştırılmış görüntüleri için Destek Vektör Makineleri ile elde edilen kullanıcı ve üretici sınıflandırma doğrulukları

DVM		Gölge	Bina	Yeşil Alan	Yol
Brovey	Kull. D.	82	69	73	61
	Üret. D.	79	84	48	41
CN	Kull. D.	81	69	73	67
	Üret. D.	70	88	43	47
Yeni Y.	Kull. D.	94	86	93	82
	Üret. D.	91	95	82	62
Ehlers	Kull. D.	94	89	90	79
	Üret. D.	92	94	79	70
Gram-S.	Kull. D.	86	90	90	85
	Üret. D.	96	94	77	67
HPF	Kull. D.	95	90	93	83
	Üret. D.	90	95	82	76
IHS	Kull. D.	83	62	63	77
	Üret. D.	72	94	32	44
Kriter T.	Kull. D.	87	91	97	86
	Üret. D.	92	96	78	72
Multip.	Kull. D.	79	71	83	64
	Üret. D.	71	89	51	45
PCA	Kull. D.	82	76	70	65
	Üret. D.	72	91	41	52
Wavelet	Kull. D.	91	88	93	79
	Üret. D.	88	96	74	68
Orijinal G.	Kull. D.	90	78	83	82
	Üret. D.	80	95	60	57

Ek Tablo 23. Orijinal İkonos ve QBPan görüntülerinin kaynaştırılması ile elde edilen görüntülerin İkili Kodlama sınıflandırıcısı ile sınıflandırılmasıyla elde edilen kullanıcı ve üretici doğrulukları

BE		Bina	Yeşil A.	Gölge	Yol
Brovey	Kull. D.	60	78	58	70
	Üret. D.	91	36	77	47
CN	Kull. D.	62	80	71	70
	Üret. D.	89	40	80	51
Yeni Y.	Kull. D.	61	72	79	66
	Üret. D.	82	68	71	52
Ehlers	Kull. D.	61	74	85	74
	Üret. D.	92	38	81	54
Gram-S.	Kull. D.	69	72	79	75
	Üret. D.	91	41	84	58
HPF	Kull. D.	74	82	63	80
	Üret. D.	93	45	83	61
IHS	Kull. D.	64	76	47	78
	Üret. D.	91	36	73	54
Kriter T.	Kull. D.	65	72	73	86
	Üret. D.	93	39	83	60
Multip.	Kull. D.	61	64	57	81
	Üret. D.	89	30	80	48
PCA	Kull. D.	64	76	55	66
	Üret. D.	89	36	76	49
Wavelet	Kull. D.	70	70	60	77
	Üret. D.	89	39	82	57
Orijinal G.	Kull. D.	68	66	60	76
	Üret. D.	90	35	79	56

Ek Tablo 24. Orijinal İkonos ve QBPan görüntülerinin kaynaştırılması ile elde edilen görüntülerin En Yakın Mesafe sınıflandırıcısı ile sınıflandırılmasıyla elde edilen kullanıcı ve üretici doğrulukları

EYM		Bina	Yeşil A.	Gölge	Yol
Brovey	Kull. D.	59	62	73	77
	Üret. D.	90	30	80	55
CN	Kull. D.	58	70	87	76
	Üret. D.	92	34	82	54
Yeni Y.	Kull. D.	70	72	78	63
	Üret. D.	51	50	87	67
Ehlers	Kull. D.	70	70	71	73
	Üret. D.	93	39	81	54
Gram-S.	Kull. D.	72	80	71	80
	Üret. D.	92	43	88	62
HPF	Kull. D.	73	84	60	83
	Üret. D.	93	47	82	62
IHS	Kull. D.	65	56	68	68
	Üret. D.	90	29	78	50
Kriter T.	Kull. D.	74	72	66	77
	Üret. D.	93	43	82	57
Multip.	Kull. D.	57	72	65	73
	Üret. D.	88	33	80	50
PCA	Kull. D.	61	72	60	75
	Üret. D.	90	34	77	52
Wavelet	Kull. D.	68	76	68	78
	Üret. D.	92	45	81	53
Orijinal G.	Kull. D.	63	70	68	76
	Üret. D.	93	35	78	54

Ek Tablo 25. Orijinal İkonos ve QBPan görüntülerinin kaynaştırılması ile elde edilen görüntülerin Maksimum Benzerlik sınıflandırıcısı ile sınıflandırılmasıyla elde edilen kullanıcı ve üretici doğrulukları

MB		Bina	Yeşil A.	Gölge	Yol
Brovey	Kull. D.	66	74	46	73
	Üret. D.	90	34	74	54
CN	Kull. D.	73	78	65	84
	Üret. D.	93	45	83	62
Yeni Y.	Kull. D.	81	68	51	74
	Üret. D.	92	53	76	61
Ehlers	Kull. D.	78	70	84	83
	Üret. D.	94	46	86	68
Gram-S.	Kull. D.	80	90	84	87
	Üret. D.	96	60	89	72
HPF	Kull. D.	87	84	82	84
	Üret. D.	98	59	91	73
IHS	Kull. D.	62	64	52	75
	Üret. D.	89	32	73	50
Kriter T.	Kull. D.	81	84	80	84
	Üret. D.	96	53	92	71
Multip.	Kull. D.	61	74	52	74
	Üret. D.	89	35	71	51
PCA	Kull. D.	62	68	65	75
	Üret. D.	91	35	78	51
Wavelet	Kull. D.	77	92	79	90
	Üret. D.	96	56	89	71
Orijinal G.	Kull. D.	70	82	77	81
	Üret. D.	92	46	84	62

Ek Tablo 26. Orijinal İkonos ve QBPan görüntülerinin kaynaştırılması ile elde edilen görüntülerin Yapay Sinir Ağları sınıflandırıcısı ile sınıflandırılmasıyla elde edilen kullanıcı ve üretici doğrulukları

YSA		Bina	Yeşil A.	Gölge	Yol
Brovey	Kull. D.	58	66	61	80
	Üret. D.	88	32	75	53
CN	Kull. D.	78	84	69	75
	Üret. D.	94	48	84	64
Yeni Y.	Kull. D.	78	74	77	53
	Üret. D.	56	56	52	48
Ehlers	Kull. D.	77	80	84	82
	Üret. D.	95	50	87	69
Gram-S.	Kull. D.	80	94	85	84
	Üret. D.	96	60	91	71
HPF	Kull. D.	81	90	85	91
	Üret. D.	97	60	94	73
IHS	Kull. D.	68	70	49	67
	Üret. D.	88	36	72	51
Kriter T.	Kull. D.	82	84	79	91
	Üret. D.	95	59	89	74
Multip.	Kull. D.	59	66	65	78
	Üret. D.	88	35	80	51
PCA	Kull. D.	61	62	85	74
	Üret. D.	91	32	84	54
Wavelet	Kull. D.	78	88	84	77
	Üret. D.	95	53	88	67
Orijinal G.	Kull. D.	72	82	74	73
	Üret. D.	94	43	87	58

Ek Tablo 27. Orijinal İkonos ve QBPan görüntülerinin kaynaştırılması ile elde edilen görüntülerin Rastgele Orman sınıflandırıcısı ile sınıflandırılmasıyla elde edilen kullanıcı ve üretici doğrulukları

RO		Bina	Yeşil A.	Gölge	Yol
Brovey	Kull. D.	66	66	66	74
	Üret. D.	91	34	79	55
CN	Kull. D.	76	86	84	73
	Üret. D.	96	46	86	65
Yeni Y.	Kull. D.	82	77	74	53
	Üret. D.	71	79	82	67
Ehlers	Kull. D.	81	82	82	86
	Üret. D.	97	54	88	72
Gram-S.	Kull. D.	82	90	90	80
	Üret. D.	96	59	91	72
HPF	Kull. D.	83	96	84	88
	Üret. D.	96	64	91	74
IHS	Kull. D.	63	70	53	75
	Üret. D.	89	33	77	53
Kriter T.	Kull. D.	86	76	84	83
	Üret. D.	95	58	89	74
Multip.	Kull. D.	67	72	57	68
	Üret. D.	91	36	75	50
PCA	Kull. D.	65	84	69	74
	Üret. D.	90	41	84	56
Wavelet	Kull. D.	79	84	84	88
	Üret. D.	95	56	91	72
Orijinal G.	Kull. D.	72	76	76	88
	Üret. D.	93	44	87	68

Ek Tablo 28. Orijinal İkonos ve QBPan görüntülerinin kaynaştırılması ile elde edilen görüntülerin Destek Vektör Makineleri sınıflandırıcısı ile sınıflandırılmasıyla elde edilen kullanıcı ve üretici doğrulukları

DVM		Bina	Yeşil A.	Gölge	Yol
Brovey	Kull. D.	65	80	80	71
	Üret. D.	89	40	86	57
CN	Kull. D.	78	80	73	82
	Üret. D.	94	57	77	64
Yeni Y.	Kull. D.	84	84	83	69
	Üret. D.	71	70	74	56
Ehlers	Kull. D.	81	80	87	81
	Üret. D.	95	60	83	68
Gram-S.	Kull. D.	85	94	79	91
	Üret. D.	95	69	84	81
HPF	Kull. D.	87	84	92	88
	Üret. D.	96	70	84	81
IHS	Kull. D.	67	60	65	67
	Üret. D.	92	35	67	49
Kriter T.	Kull. D.	83	76	85	88
	Üret. D.	97	61	84	71
Multip.	Kull. D.	66	70	60	77
	Üret. D.	91	43	63	54
PCA	Kull. D.	71	74	63	77
	Üret. D.	93	43	66	60
Wavelet	Kull. D.	83	78	79	88
	Üret. D.	96	52	89	76
Orijinal G.	Kull. D.	74	88	80	77
	Üret. D.	96	49	86	63

Ek Tablo 29. Landsat ETM+ kaynaştırılmış görüntülerinin sınıflandırılması ile elde edilen Kappa değerleri

		SU	ORMAN	KENT	TOPRAK
İKİLİ KODLAMA	ORJİNAL GÖRÜNTÜ	0,7407	0,3989	0,4512	0,4014
	BROVEY	0,6691	0,3280	0,4067	0,5335
	CN	0,7310	0,3469	0,6149	0,5401
	EHLERS	0,6968	0,3871	0,6951	0,5412
	GRAM-SCHMIDT	0,7459	0,3907	0,7487	0,3372
	HPF	0,6591	0,5325	0,5706	0,6445
	IHS	0,6002	0,2947	0,3902	0,1863
	KRİTER TAB.	0,7149	0,5418	0,5460	0,6793
	MULTIPLICATIVE	0,7496	0,3919	0,3258	0,3652
	PCA	0,7596	0,3576	0,6332	0,4000
	DALGACIK D.	0,7299	0,3729	0,5554	0,4630
	YENİ YÖNTEM	0,7046	0,5353	0,5213	0,6862
EN YAKIN MESAFE	ORJİNAL GÖRÜNTÜ	0,6743	0,4221	0,3124	0,5290
	BROVEY	0,5586	0,3472	0,4811	0,5433
	CN	0,7129	0,3892	0,4292	0,3750
	EHLERS	0,7236	0,4166	0,5330	0,6495
	GRAM-SCHMIDT	0,6542	0,3950	0,5023	0,6479
	HPF	0,7323	0,4146	0,5829	0,7524
	IHS	0,5766	0,3182	0,1008	0,3165
	KRİTER TAB.	0,6059	0,4697	0,4811	0,4643
	MULTIPLICATIVE	0,6267	0,4388	0,3529	0,3478
	PCA	0,6532	0,3948	0,3040	0,3214
	DALGACIK D.	0,5861	0,3488	0,3048	0,3245
	YENİ YÖNTEM	0,6556	0,5050	0,4213	0,4000
MAKSİMUM BENZERLİK	ORJİNAL GÖRÜNTÜ	0,7877	0,7400	0,7091	0,8210
	BROVEY	0,7677	0,6429	0,8131	0,8210
	CN	0,7964	0,7284	0,8394	0,8219
	EHLERS	0,7907	0,7660	0,8386	0,7512
	GRAM-SCHMIDT	0,8880	0,7955	0,7336	0,7500
	HPF	0,9106	0,8694	0,7858	0,7500
	IHS	0,7037	0,6853	0,5547	0,6786
	KRİTER TAB.	0,8294	0,7775	0,8658	0,8214
	MULTIPLICATIVE	0,8008	0,6898	0,6826	0,7862
	PCA	0,7815	0,6814	0,6819	0,7500
	DALGACIK D.	0,8433	0,8475	0,6826	0,7847
	YENİ YÖNTEM	0,8975	0,8690	0,8000	0,7208

Ek Tablo 29' un devamı

YAPAY SINIR AĞLARI	ORJİNAL GÖRÜNTÜ	0,8521	0,8332	0,7853	0,7150
	BROVEY	0,7919	0,6731	0,8405	0,9287
	CN	0,8510	0,8140	0,8402	0,8934
	EHLERS	0,8911	0,8520	0,9731	0,9287
	GRAM-SCHMIDT	0,7271	0,6911	0,8913	0,8575
	HPF	0,9493	0,9213	0,8668	0,7529
	IHS	0,7324	0,6619	0,6849	0,8916
	KRİTER TAB.	0,9211	0,9017	0,7874	0,8219
	MULTIPLICATIVE	0,7823	0,6970	0,7355	0,8568
	PCA	0,7919	0,6936	0,8131	0,8214
	DALGACIK D.	0,9007	0,8694	0,8394	0,8214
	YENİ YÖNTEM	0,9334	0,9290	0,8411	0,7234
RASTGELE ORMAN	ORJİNAL GÖRÜNTÜ	0,8662	0,7708	0,8135	0,8578
	BROVEY	0,8445	0,7528	0,7098	0,8575
	CN	0,8989	0,8353	0,7602	0,7867
	EHLERS	0,7010	0,6840	0,8934	0,9287
	GRAM-SCHMIDT	0,9383	0,8225	0,8665	0,8934
	HPF	0,9500	0,8873	0,8665	0,8929
	IHS	0,6971	0,6250	0,6288	0,6824
	KRİTER TAB.	0,9003	0,8689	0,8394	0,8223
	MULTIPLICATIVE	0,7782	0,6577	0,9461	0,8231
	PCA	0,7911	0,6970	0,8390	0,7190
	DALGACIK D.	0,5205	0,3537	0,5829	0,8206
	YENİ YÖNTEM	0,8332	0,8560	0,7914	0,8777
DESTEK VEKTÖR MAKİNELERİ	ORJİNAL GÖRÜNTÜ	0,8335	0,7946	0,9154	0,8892
	BROVEY	0,7914	0,7662	0,9717	0,7778
	CN	0,7823	0,8367	0,9721	0,9631
	EHLERS	0,9426	0,8822	0,8628	0,8175
	GRAM-SCHMIDT	0,8692	0,9304	0,8913	0,9632
	HPF	0,9331	0,8982	0,9727	0,9270
	IHS	0,7187	0,5894	0,8826	0,7662
	KRİTER TAB.	0,8825	0,8928	0,8668	0,8571
	MULTIPLICATIVE	0,8070	0,7225	0,9147	0,8492
	PCA	0,8168	0,7881	0,9719	0,9250
	DALGACIK D.	0,9400	0,8792	0,7869	0,7847
	YENİ YÖNTEM	0,8666	0,8531	0,8090	0,7495

Ek Tablo 30. Worldview-2 kaynaştırılmış görüntülerinin sınıflandırılması ile elde edilen Kappa değerleri

		SU	YOL	FINDIK	ORMAN	KAYALIK	TOPRAK	ÇAY	BİNA	GÖLGE
İKİLİ KODLAMA	OG	0,8508	0,3191	0,1942	0,1673	0,7491	0,5742	0,2190	0,7301	0,5687
	BR	0,9252	0,2440	0,2396	0,3743	0,6790	0,5460	0,2282	0,4737	0,6324
	CN	0,7808	0,2780	0,2871	0,2385	0,7497	0,5134	0,2788	0,4015	0,6333
	EH	0,7975	0,2754	0,2439	0,3262	0,7844	0,5449	0,3864	0,8834	0,7637
	GS	0,7403	0,1435	0,1442	0,2436	-0,0071	0,1627	0,1881	-0,0875	0,1016
	HPF	0,9060	0,3143	0,2436	0,3160	0,9640	0,5742	0,5014	0,6970	0,7320
	IHS	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
	KT	0,9434	0,2493	0,3390	0,3271	0,5055	0,4975	0,4003	0,4272	0,4401
	MUL	0,8875	0,1270	0,2454	0,3227	0,5409	0,7222	0,2327	0,4737	0,7333
	PCA	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
	DD	0,8130	0,3814	0,1931	0,2446	0,7154	0,5404	0,1488	0,8831	0,6674
YY	0,8705	0,1660	0,2594	0,2707	0,8933	0,6350	0,3989	0,7315	0,8308	
EN YAKIN MESAFE	OG	0,8694	0,2301	0,2101	0,0897	0,2360	0,1627	0,2253	0,4656	0,3444
	BR	0,8504	0,0511	0,2594	0,2048	0,3173	0,1135	0,2647	0,1000	0,4013
	CN	0,8496	0,0619	0,2246	0,1724	0,4363	0,0818	0,1826	0,3701	0,3428
	EH	0,9057	0,4673	0,2191	0,3073	0,0795	0,5614	0,2771	0,1750	0,3491
	GS	0,8881	0,3046	0,1857	0,2322	0,3673	0,5998	0,3528	0,0370	0,6599
	HPF	0,8531	0,1582	0,2733	0,4097	0,4778	0,3705	0,2383	0,5038	0,6259
	IHS	0,8484	0,3325	0,1754	0,1878	0,1056	0,2280	0,1197	0,3846	0,1337
	KT	0,9052	0,1168	0,2173	0,2446	0,7147	0,6613	0,1865	0,4030	0,6333
	MUL	0,9042	0,2037	0,1888	0,1844	0,1725	0,1135	0,1768	0,2730	0,2874
	PCA	0,8684	0,0641	0,1955	0,1746	0,5375	0,0499	0,3113	0,1964	0,2532
	DD	0,7563	0,0511	0,2071	0,1188	0,2970	-0,0024	0,0778	-0,0606	0,0974
YY	0,9055	0,3095	0,1793	0,2201	0,8195	0,5449	0,3345	0,3284	0,6658	
MAKSİMUM BENZERLİK	OG	0,8738	0,4423	0,4100	0,4962	0,9283	0,8153	0,4873	0,6970	0,7365
	BR	0,8206	0,4656	0,4557	0,3891	0,6829	0,4033	0,3034	0,6970	0,7333
	CN	0,8558	0,4329	0,4461	0,4545	0,8938	0,7549	0,5038	0,3796	0,9325
	EH	0,9072	0,6002	0,4199	0,5768	0,6511	0,8771	0,6724	0,6278	0,9328
	GS	0,8202	0,6651	0,4445	0,5589	0,8938	0,7256	0,6724	0,5926	0,8660
	HPF	0,8377	0,6447	0,6411	0,5779	0,8594	0,7871	0,6117	0,5599	0,9000
	IHS	0,8705	0,2457	0,3885	0,2910	0,4741	0,4263	0,2898	0,1852	0,7333
	KT	0,8164	0,6883	0,5291	0,6363	0,8591	0,9083	0,7360	0,2536	0,8676
	MUL	0,7820	0,3771	0,3902	0,4384	0,6494	0,3437	0,2419	0,5812	0,6028
	PCA	0,8901	0,3525	0,4788	0,4387	0,7174	0,5783	0,4620	0,5906	0,8329
	DD	0,8569	0,5973	0,4020	0,5959	0,9643	0,8771	0,6107	0,7007	0,8995
YY	0,8547	0,9022	0,4682	0,6151	0,9643	0,7561	0,6740	0,4578	0,8028	

Ek Tablo 30' un devamı

YAPAY SİNİR AĞLARI	OG	0,8390	0,3785	0,4028	0,4882	0,9287	0,6671	0,5664	0,7716	0,8000
	BR	0,8022	0,5564	0,4109	0,5817	0,6511	0,7215	0,3213	0,3099	0,8325
	CN	0,9089	0,4463	0,4431	0,4530	0,9283	0,5504	0,5219	0,7368	0,7021
	EH	0,8915	0,4693	0,4737	0,5757	0,9645	0,5482	0,6708	0,7767	0,8670
	GS	0,8558	0,4232	0,4983	0,6556	0,8208	0,8166	0,6314	0,8507	0,9665
	HPF	0,8569	0,5532	0,4738	0,7730	0,9265	0,8180	0,7794	0,7401	0,9664
	IHS	0,7848	0,2864	0,3795	0,4384	0,3433	0,4867	0,5207	0,5113	0,5378
	KT	0,8543	0,6906	0,4300	0,5201	0,9292	0,8765	0,7118	0,7805	0,9000
	MUL	0,8725	0,4827	0,3601	0,5048	0,8935	0,5438	0,3261	0,4815	0,8018
	PCA	0,8369	0,4163	0,4552	0,4936	0,8243	0,6671	0,5850	0,6259	0,7014
	DD	0,8361	0,7369	0,3982	0,6929	0,9645	0,7263	0,6078	0,5244	0,9328
YY	0,8913	0,5807	0,6203	0,5201	0,7901	0,7567	0,6732	0,7789	0,7365	
RASTGELE ORMAN	OG	0,8569	0,5155	0,5258	0,4747	0,8946	0,6695	0,5657	0,4565	0,9009
	BR	0,9252	0,3387	0,3669	0,4156	0,8225	0,7555	0,6453	0,3099	0,8329
	CN	0,8527	0,6237	0,4036	0,6363	0,8935	0,8464	0,6904	0,5966	0,8019
	EH	0,8369	0,6040	0,4083	0,6759	0,8935	0,8472	0,7366	0,9248	0,8992
	GS	0,8893	0,6273	0,4564	0,6538	0,8591	0,7269	0,7161	0,9628	0,8670
	HPF	0,9080	0,6031	0,4738	0,6601	0,9265	0,9076	0,6935	0,9248	0,8670
	IHS	0,8520	0,1978	0,2794	0,4160	0,5762	0,6305	0,3666	0,3366	0,6674
	KT	0,9080	0,5827	0,4786	0,6556	0,9644	0,7269	0,6708	0,8265	0,8345
	MUL	0,8550	0,7151	0,3495	0,4222	0,7208	0,4048	0,6399	0,4853	0,4225
	PCA	0,8394	0,3615	0,4019	0,4283	0,8225	0,7845	0,4391	0,5533	0,9327
	DD	0,8725	0,6489	0,4578	0,6501	0,9294	0,7579	0,6462	0,4891	0,9330
YY	0,8531	0,6928	0,4518	0,6776	0,9647	0,7573	0,6935	0,9250	0,9002	
DESTEK VEKTÖR MAKİNELERİ	OG	0,8715	0,6456	0,4052	0,6335	0,7870	0,8171	0,6514	0,4189	0,9323
	BR	0,9077	0,4514	0,3404	0,4719	0,6726	0,7266	0,4646	0,6633	0,6386
	CN	0,7303	0,7178	0,4668	0,5520	0,7516	0,8771	0,7586	0,8139	0,7371
	EH	0,7842	0,6921	0,6029	0,7636	0,6552	0,7886	0,6305	0,7445	0,5176
	GS	0,8715	0,6844	0,4635	0,7164	0,9646	0,7866	0,7567	0,7831	0,7678
	HPF	0,8365	0,6950	0,5508	0,7380	0,9649	0,7296	0,8015	0,9257	0,9336
	IHS	0,9439	0,4286	0,3072	0,4176	0,5464	0,4904	0,4679	0,5209	0,6690
	KT	0,9082	0,6273	0,5391	0,7186	0,8943	0,9079	0,6927	0,5642	0,8977
	MUL	0,7986	0,6273	0,2379	0,5008	0,9645	0,1570	0,6231	0,8875	0,8657
	PCA	0,7986	0,5097	0,4075	0,4975	0,8580	0,7543	0,5621	0,5577	0,7666
	DD	0,8712	0,5330	0,5103	0,5250	0,8940	0,9076	0,7353	0,8148	0,8345
YY	0,8547	0,6950	0,5323	0,8540	0,7906	0,8479	0,7161	0,4643	0,9336	

Ek Tablo 31. İkonos kaynaştırılmış görüntülerinin sınıflandırılması ile elde edilen Kappa değerleri

		GÖLGE	BİNA	YEŞİL A.	YOL
İKİLİ KODLAMA	ORJİNAL GÖRÜNTÜ	0,8224	0,4152	0,6650	0,4318
	BROVEY	0,8068	0,1747	0,7656	-0,0430
	CN	0,6625	0,4043	0,8106	0,6519
	EHLERS	0,8390	0,3840	0,8489	0,5519
	GRAM-SCHMIDT	0,8079	0,4538	0,8507	0,6309
	HPF	0,8712	0,4416	0,7772	0,4872
	IHS	0,6806	0,2646	0,4000	0,4801
	KRİTER TAB.	0,8079	0,3899	0,7744	0,5507
	MULTIPLICATIVE	0,8073	0,1813	0,6883	0,0569
	PCA	0,7459	0,1752	0,6850	0,1202
	DALGACIK D.	0,7930	0,4126	0,8120	0,4129
YENİ YÖNTEM	0,7783	0,3842	0,8092	0,5989	
EN YAKIN MESAFE	ORJİNAL GÖRÜNTÜ	0,7565	0,3489	0,7328	0,5325
	BROVEY	0,7271	0,3078	0,4059	0,4770
	CN	0,8073	0,3449	0,8096	0,5243
	EHLERS	0,8041	0,3542	0,6278	0,5652
	GRAM-SCHMIDT	0,7752	0,4118	0,8130	0,5558
	HPF	0,8219	0,4233	0,8120	0,5252
	IHS	0,4986	0,3047	0,4059	0,4215
	KRİTER TAB.	0,8518	0,3808	0,7733	0,5378
	MULTIPLICATIVE	0,5079	0,3038	0,6939	0,6445
	PCA	0,5660	0,3204	0,7328	0,6477
	DALGACIK D.	0,7884	0,3777	0,7704	0,5921
YENİ YÖNTEM	0,8358	0,3808	0,7767	0,5677	
MAKSİMUM BENZERLİK	ORJİNAL GÖRÜNTÜ	0,8888	0,4881	0,7756	0,7018
	BROVEY	0,8841	0,1847	0,6512	0,1304
	CN	0,8575	0,4821	0,7772	0,7061
	EHLERS	0,9208	0,6095	0,7094	0,7727
	GRAM-SCHMIDT	0,9052	0,6034	0,9259	0,7740
	HPF	0,8272	0,6584	0,8908	0,7795
	IHS	0,7172	0,3474	0,4776	0,5415
	KRİTER TAB.	0,8263	0,6239	0,8900	0,7221
	MULTIPLICATIVE	0,7618	0,3104	0,5533	0,5101
	PCA	0,8084	0,3342	0,6296	0,5115
	DALGACIK D.	0,8050	0,5939	0,8162	0,6789
YENİ YÖNTEM	0,8873	0,5583	0,8540	0,7151	

Ek Tablo 31' in devamı


YAPAY SINIR AĞLARI	ORJİNAL GÖRÜNTÜ	0,8743	0,5496	0,8522	0,7676
	BROVEY	0,8330	0,3579	0,6992	0,5690
	CN	0,7801	0,5863	0,8166	0,8648
	EHLERS	0,9015	0,6390	0,8522	0,7251
	GRAM-SCHMIDT	0,9057	0,7016	0,8910	0,7967
	HPF	0,9052	0,6995	0,9272	0,7962
	IHS	0,6385	0,4318	0,5522	0,4740
	KRİTER TAB.	0,8135	0,5105	0,7059	0,7977
	MULTIPLICATIVE	0,8258	0,4203	0,5545	0,6347
	PCA	0,7344	0,4512	0,4853	0,6453
	DALGACIK D.	0,8740	0,6542	0,7821	0,7565
YENİ YÖNTEM	0,7452	0,3711	0,5088	0,6772	
RASTGELE ORMAN	ORJİNAL GÖRÜNTÜ	0,8719	0,4866	0,8144	0,7662
	BROVEY	0,7598	0,2129	0,7625	0,1967
	CN	0,9673	0,5358	0,8166	0,6470
	EHLERS	0,9204	0,6751	0,8547	0,6545
	GRAM-SCHMIDT	0,8747	0,6801	0,7826	0,8157
	HPF	0,8912	0,7692	0,8554	0,7461
	IHS	0,7431	0,3430	0,4132	0,3995
	KRİTER TAB.	0,8590	0,6832	0,8905	0,7765
	MULTIPLICATIVE	0,6553	0,2960	0,6591	0,4202
	PCA	0,6571	0,4019	0,6633	0,4992
	DALGACIK D.	0,8290	0,6251	0,8533	0,8090
YENİ YÖNTEM	0,8429	0,6605	0,9265	0,7783	
DESTEK VEKTÖR MAKİNELERİ	ORJİNAL GÖRÜNTÜ	0,8716	0,5609	0,8162	0,7702
	BROVEY	0,7789	0,3735	0,7030	0,4978
	CN	0,7572	0,4029	0,6992	0,5787
	EHLERS	0,9214	0,7380	0,8918	0,7461
	GRAM-SCHMIDT	0,8313	0,7481	0,8916	0,8142
	HPF	0,9366	0,7654	0,9279	0,8016
	IHS	0,7895	0,3624	0,5780	0,6929
	KRİTER TAB.	0,8450	0,7765	0,9637	0,8346
	MULTIPLICATIVE	0,7431	0,4325	0,8130	0,5403
	PCA	0,7746	0,5053	0,6617	0,5739
	DALGACIK D.	0,8894	0,7320	0,9272	0,7448
YENİ YÖNTEM	0,9212	0,6751	0,9279	0,7746	

Ek Tablo 32. İkonos – QBPan kaynaştırılmış görüntülerinin sınıflandırılması ile elde edilen Kappa değerleri

		BİNA	YEŞİL A.	GÖLGE	YOL
İKİLİ KODLAMA	ORJİNAL GÖRÜNTÜ	0,4666	0,5726	0,5558	0,6789
	BROVEY	0,3821	0,7122	0,5380	0,5755
	CN	0,3949	0,7436	0,6737	0,5884
	EHLERS	0,3991	0,6686	0,8326	0,6494
	GRAM-SCHMIDT	0,4785	0,6529	0,7625	0,6707
	HPF	0,5427	0,7750	0,5913	0,7297
	IHS	0,4257	0,6879	0,4237	0,7022
	KRİTER TAB.	0,4409	0,6480	0,6926	0,8125
	MULTIPLICATIVE	0,3798	0,5318	0,5238	0,5899
	PCA	0,4173	0,6870	0,5050	0,5441
	DALGACIK D.	0,4805	0,6271	0,5580	0,6951
YENİ YÖNTEM	0,4325	0,7147	0,6299	0,6300	
EN YAKIN MESAFE	ORJİNAL GÖRÜNTÜ	0,4230	0,6154	0,6383	0,6749
	BROVEY	0,3694	0,5086	0,6910	0,6904
	CN	0,3639	0,6121	0,8508	0,6759
	EHLERS	0,4913	0,6271	0,6745	0,6341
	GRAM-SCHMIDT	0,5180	0,7493	0,6778	0,7313
	HPF	0,5356	0,8006	0,5580	0,7727
	IHS	0,4261	0,4423	0,6383	0,5719
	KRİTER TAB.	0,5481	0,6576	0,6241	0,6960
	MULTIPLICATIVE	0,3404	0,6327	0,6062	0,6226
	PCA	0,3863	0,6358	0,5547	0,6573
	DALGACIK D.	0,4650	0,7049	0,6402	0,7103
YENİ YÖNTEM	0,5115	0,7225	0,5297	0,5105	
MAKSİMUM BENZERLİK	ORJİNAL GÖRÜNTÜ	0,4874	0,7756	0,7449	0,7455
	BROVEY	0,4379	0,6579	0,4091	0,6341
	CN	0,5374	0,7288	0,6081	0,7866
	EHLERS	0,6001	0,6400	0,8164	0,7794
	GRAM-SCHMIDT	0,6476	0,8800	0,8173	0,8387
	HPF	0,7476	0,8100	0,8001	0,7983
	IHS	0,3905	0,5385	0,4709	0,6519
	KRİTER TAB.	0,6523	0,8059	0,7830	0,7959
	MULTIPLICATIVE	0,3841	0,6609	0,4696	0,6406
	PCA	0,4014	0,5921	0,6052	0,6552
	DALGACIK D.	0,5992	0,9024	0,7643	0,8665
YENİ YÖNTEM	0,6161	0,8007	0,6314	0,7777	


Ek Tablo 32' nin devamı

YAPAY SINIR AĞLARI	ORJİNAL GÖRÜNTÜ	0,5253	0,7725	0,7114	0,6439
	BROVEY	0,3525	0,5616	0,5693	0,7152
	CN	0,6101	0,8022	0,6590	0,6812
	EHLERS	0,5960	0,7574	0,8523	0,7674
	GRAM-SCHMIDT	0,6401	0,9274	0,8356	0,7965
	HPF	0,6612	0,8803	0,8364	0,8820
	IHS	0,4492	0,6186	0,4384	0,5619
	KRİTER TAB.	0,6950	0,8100	0,7643	0,8824
	MULTIPLICATIVE	0,3604	0,5702	0,6062	0,6965
	PCA	0,3927	0,5197	0,8335	0,6472
	DALGACIK D.	0,6075	0,8533	0,8168	0,7110
	YENİ YÖNTEM	0,5957	0,8210	0,7743	0,7931
RASTGELE ORMAN	ORJİNAL GÖRÜNTÜ	0,5250	0,7041	0,7288	0,8498
	BROVEY	0,4467	0,5666	0,6222	0,6515
	CN	0,5840	0,8240	0,8164	0,6562
	EHLERS	0,6612	0,7840	0,7991	0,8246
	GRAM-SCHMIDT	0,6708	0,8797	0,8895	0,7429
	HPF	0,6964	0,9520	0,8178	0,8542
	IHS	0,3971	0,6110	0,4898	0,6584
	KRİTER TAB.	0,7328	0,7195	0,8173	0,7851
	MULTIPLICATIVE	0,4514	0,6410	0,5203	0,5732
	PCA	0,4240	0,7937	0,6590	0,6526
	DALGACIK D.	0,6251	0,8080	0,8178	0,8529
	YENİ YÖNTEM	0,6645	0,7519	0,7743	0,8202
DESTEK VEKTÖR MAKİNELERİ	ORJİNAL GÖRÜNTÜ	0,5622	0,8504	0,7808	0,7059
	BROVEY	0,4218	0,7429	0,7808	0,6154
	CN	0,6101	0,7632	0,6894	0,7619
	EHLERS	0,6555	0,7656	0,8512	0,7529
	GRAM-SCHMIDT	0,7123	0,9293	0,7625	0,8854
	HPF	0,7512	0,8154	0,9063	0,8580
	IHS	0,4582	0,5068	0,5960	0,5566
	KRİTER TAB.	0,6861	0,7216	0,8335	0,8521
	MULTIPLICATIVE	0,4399	0,6341	0,5421	0,6885
	PCA	0,5114	0,6795	0,5788	0,7006
	DALGACIK D.	0,6835	0,7360	0,7643	0,8551
	YENİ YÖNTEM	0,7136	0,7530	0,7255	0,8233





Ek Şekil 1. Worldview-2 MS–Worldview-2 Pan kaynaştırılmış - sınıflandırılmış görüntüler

Ek Şekil 1' in devamı




Ek Şekil 1' in devamı



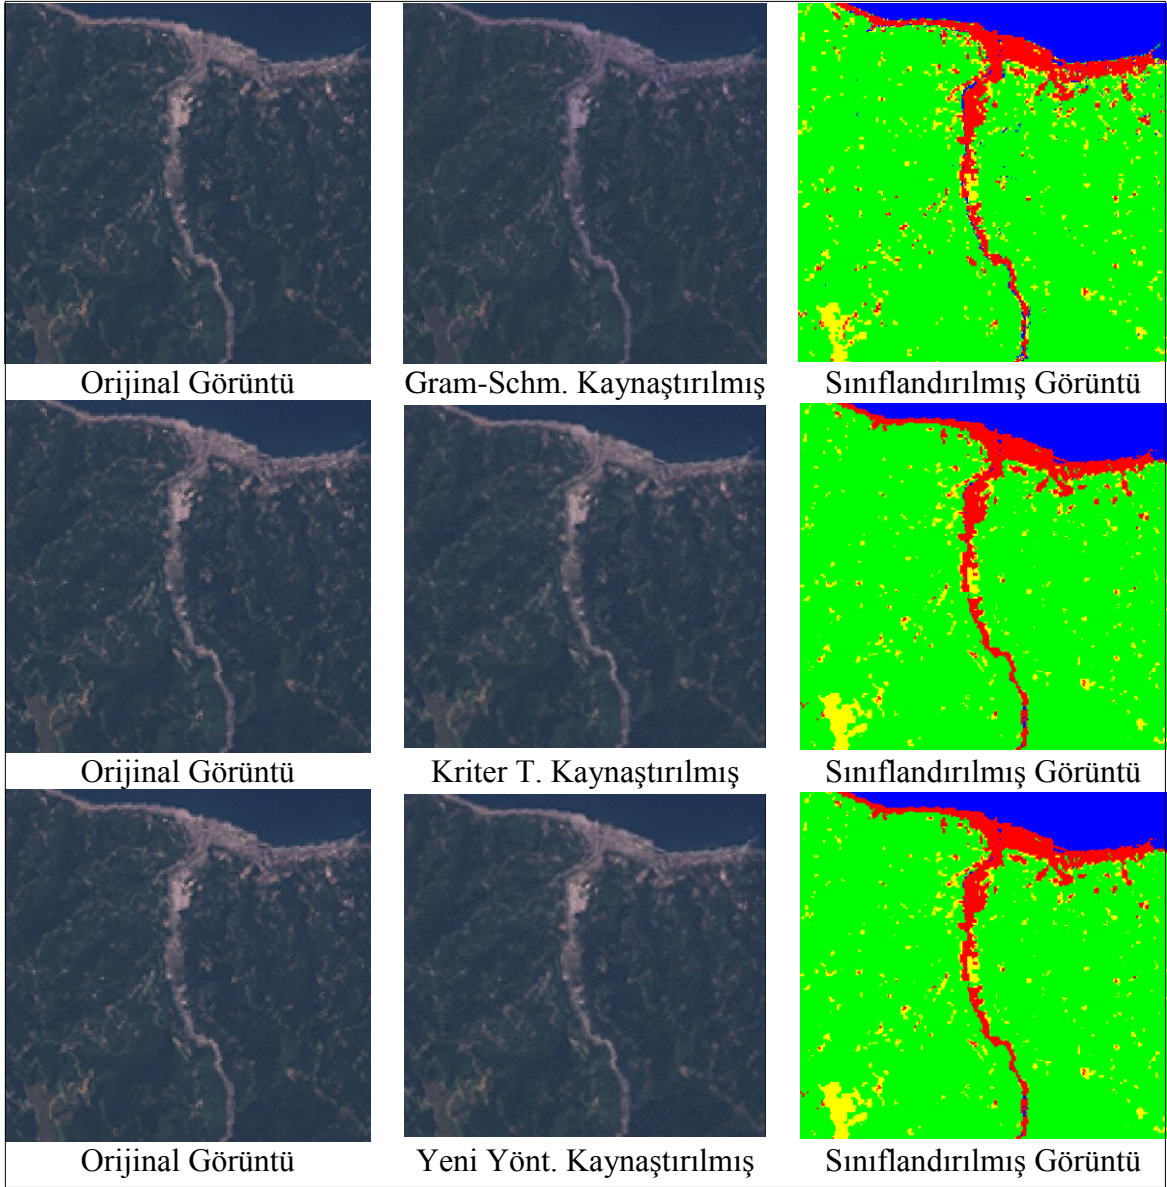



Ek Şekil 2. Landsat ETM MS – Landsat ETM Pan kaynaştırılmış - sınıflandırılmış görüntüler

Ek Şekil 2' nin devamı




Ek Şekil 2' nin devamı







Ek Şekil 3. İkonos MS – İkonos Pan kaynaştırılmış – sınıflandırılmış görüntüler

Ek Şekil 3' ün devamı




Ek Şekil 3' ün devamı






Ek Şekil 4. Ikonos MS – QBPan kaynaştırılmış – sınıflandırılmış görüntüler

Ek Şekil 4' ün devamı



Ek Şekil 4' ün devamı



ÖZGEÇMİŞ

03.03.1987 yılında Trabzon'da doğdu. 2000 – 2005 yılları arasında Akçaabat Anadolu Lisesi'nde lise eğitimi gördü. 2005 yılında Karadeniz Teknik Üniversitesi Harita Mühendisliği bölümünü kazandı. 4 yıllık eğitimin ardından 2009 yılında lisans eğitimini tamamladı. Aynı yıl Karadeniz Teknik Üniversitesi'nde yüksek lisans eğitimine başladı. 2010 yılının Temmuz ayında Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Harita Mühendisliği Anabilim Dalı'na Araştırma Görevlisi olarak atandı. Yüksek Lisans eğitimi halen devam etmektedir. İngiltere'de dil eğitimi almıştır, iyi seviyede İngilizce bilmektedir.