

**İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ**

**YÜKSEK ÇÖZÜNÜRLÜKLÜ UYDU GÖRÜNTÜLERİ KULLANARAK  
BENZER SPEKTRAL ÖZELLİKLERE SAHİP DOĞAL NESNELERİN AYIRT  
EDİLMESİNE YÖNELİK BİR METODOLOJİ GELİŞTİRME**

**DOKTORA TEZİ**

**İsmail ÇÖLKESEN**

**Geomatik Mühendisliği Anabilim Dalı**

**Geomatik Mühendisliği Programı**

**Tez Danışmanı: Prof. Dr. Tahsin YOMRALIOĞLU**

**OCAK 2015**



**İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ**

**YÜKSEK ÇÖZÜNÜRLÜKLÜ UYDU GÖRÜNTÜLERİ KULLANARAK  
BENZER SPEKTRAL ÖZELLİKLERE SAHİP DOĞAL NESNELERİN AYIRT  
EDİLMESİNE YÖNELİK BİR METODOLOJİ GELİŞTİRME**

**DOKTORA TEZİ**

**İsmail ÇÖLKESEN  
(501102602)**

**Geomatik Mühendisliği Anabilim Dalı**

**Geomatik Mühendisliği Programı**

**Tez Danışmanı: Prof. Dr. Tahsin YOMRALIOĞLU**

**OCAK 2015**





İTÜ, Fen Bilimleri Enstitüsü'nün 501102602 numaralı Doktora Öğrencisi **İsmail ÇÖLKESEN** ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “**Uzaktan Algılamada Benzer Spektral Özelliklere Sahip Doğal Nesnelerin Ayırt Edilmesine Yönelik Bir Metodoloji Geliştirme**” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

**Tez Danışmanı :**      **Prof. Dr. Tahsin YOMRALIOĞLU** .....  
İstanbul Teknik Üniversitesi

**Jüri Üyeleri :**      **Doç. Dr. Arif Çağdaş AYDINOĞLU** .....  
İstanbul Teknik Üniversitesi

**Doç. Dr. Şinasi KAYA** .....  
İstanbul Teknik Üniversitesi

**Prof. Dr. Taşkın KAVZOĞLU** .....  
Gebze Teknik Üniversitesi

**Prof. Dr. Cem GAZİOĞLU** .....  
İstanbul Üniversitesi

**Teslim Tarihi :**      **25 Aralık 2014**  
**Savunma Tarihi :**      **22 Ocak 2015**



*Eşim Solmaz, ikizlerim Ömer ve Elif'e,*



## ÖNSÖZ

Doktora eğitimim süresince ve tez çalışmasının tüm aşamalarında akademik bilgi ve tecrübeleriyle çalışmalarına ışık tutan, benden yardımlarını, desteğini ve sabrını esirgemeyen değerli hocam ve aynı zamanda tez danışmanım Prof. Dr. Tahsin YOMRALIOĞLU'na,

Doktora tez çalışmamda, tez konusunun seçiminden hazırlanmasına kadar tüm aşamalarında değerli görüşlerinden ve bilgisinden istifade ettiğim, bilimsel ve manevi desteğini hiçbir zaman esirgemeyen değerli hocam Prof.Dr. Taşkın KAVZOĞLU'na,

Tez araştırması süresince değerli fikirleri yol gösteren ve tez çalışmalarının olgunlaşmasındaki katkılarından dolayı değerli hocam Doç.Dr. Arif Çağdaş AYDINOĞLU'na ve bölümümüzde görev yapmakta olan değerli öğretim elemanlarına, tez çalışmam süresince desteğini esirgemeyen çalışma arkadaşım Arş.Gör. Emrehan Kutluğ ŞAHİN'e,

Son olarak tez çalışmam boyunca gösterdiği anlayış ve verdiği manevi destek için eşim Solmaz ÇÖLKESEN'e, bu günlere gelmemde büyük pay sahibi olan anne ve babama,

Teşekkürlerimi sunarım.

Ocak 2014

İsmail ÇÖLKESEN  
(Harita Mühendisi)



## İÇİNDEKİLER

### Sayfa

|                                                                        |      |
|------------------------------------------------------------------------|------|
| ÖNSÖZ.....                                                             | v    |
| İÇİNDEKİLER .....                                                      | vii  |
| KISALTMALAR .....                                                      | xi   |
| ÇİZELGE LİSTESİ.....                                                   | xiii |
| ŞEKİL LİSTESİ.....                                                     | xv   |
| ÖZET.....                                                              | xix  |
| SUMMARY .....                                                          | xxi  |
| 1. GİRİŞ .....                                                         | 1    |
| 1.1 Problem Tanımı.....                                                | 3    |
| 1.2 Çalışmanın Amacı .....                                             | 6    |
| 1.3 Metodoloji .....                                                   | 7    |
| 1.4 Literatür Çalışması .....                                          | 11   |
| 2. UZAKTAN ALGILAMADA TEMEL TANIM VE KAVRAMLAR.....                    | 21   |
| 2.1 Enerji Kaynağı ve Elektromanyetik Enerji .....                     | 21   |
| 2.2 Enerji-Atmosfer Etkileşimi ve Atmosferik Pencereleler .....        | 23   |
| 2.3 Enerji-Nesne Etkileşimi ve Nesnelerin Spektral İmzası .....        | 24   |
| 2.4 Uzaktan Algılamada Çözünürlük.....                                 | 29   |
| 2.5 Uzaktan Algılamada Görüntü Analizi ve Ön İşlemler .....            | 30   |
| 2.5.1 Atmosferik düzeltmeler.....                                      | 31   |
| 2.5.2 Geometrik düzeltmeler.....                                       | 33   |
| 2.5.3 Görüntü kaynaştırma.....                                         | 35   |
| 2.6 Uzaktan Algılamada Görüntü Dönüşümleri.....                        | 36   |
| 2.6.1 Vejetasyon indeksleri.....                                       | 37   |
| 2.6.2 Doku özellikleri.....                                            | 38   |
| 2.6.3 Temel bileşen analizi .....                                      | 39   |
| 2.6.4 Ton-doygunluk-yoğunluk (Hue-Saturation-Intensity) dönüşümü ..... | 41   |
| 2.7 Uzaktan Algılamada Görüntü Sınıflandırma .....                     | 42   |
| 2.7.1 Kontrolsüz sınıflandırma.....                                    | 44   |
| 2.7.2 Kontrollü sınıflandırma.....                                     | 44   |
| 2.7.2.1 Piksel tabanlı sınıflandırma.....                              | 45   |
| 2.7.2.2 Alt-piksel tabanlı sınıflandırma .....                         | 46   |
| 2.7.2.3 Obje tabanlı sınıflandırma.....                                | 47   |
| 2.8 Sınıflandırma Algoritmaları .....                                  | 53   |
| 2.8.1 En yakın komşuluk.....                                           | 54   |
| 2.8.2 Destek vektör makineleri .....                                   | 55   |
| 2.8.3 Karar ağaçları .....                                             | 60   |
| 2.8.4 Toplu öğrenme algoritmaları .....                                | 62   |
| 2.8.4.1 Hızlandırma algoritması.....                                   | 62   |
| 2.8.4.2 Torbalama .....                                                | 63   |

|                                                                                 |            |
|---------------------------------------------------------------------------------|------------|
| 2.8.4.3 Çoklu hızlandırma .....                                                 | 64         |
| 2.8.4.4 Rastgele orman algoritması .....                                        | 64         |
| 2.8.4.5 Rotasyon orman algoritması .....                                        | 65         |
| 2.9 Uzaktan Algılamada Özellik Seçimi .....                                     | 68         |
| 2.9.1 Ki-kare testi .....                                                       | 72         |
| 2.9.2 Fisher testi .....                                                        | 72         |
| 2.9.3 Bilgi kazancı .....                                                       | 73         |
| 2.9.4 Kazanç oranı .....                                                        | 74         |
| 2.9.5 Naive bayes .....                                                         | 74         |
| 2.9.6 Pearson's korelasyonu .....                                               | 75         |
| 2.9.7 One-R .....                                                               | 76         |
| 2.9.8 Olasılıksal anlamlılık .....                                              | 77         |
| 2.9.9 ReliefF .....                                                             | 77         |
| 2.9.10 Rastgele orman .....                                                     | 78         |
| 2.9.11 Özyinelemeli özellik eleme esasına dayalı destek vektör makineleri ..... | 79         |
| 2.9.12 Simetrik belirsizlik .....                                               | 79         |
| 2.9.13 t-test .....                                                             | 80         |
| <b>3. ÇALIŞMA ALANI VE VERİ TOPLAMA İŞLEMLERİ .....</b>                         | <b>81</b>  |
| 3.1 Çalışma Alanı .....                                                         | 81         |
| 3.2 Uygulama Konusu ve Amacı .....                                              | 82         |
| 3.3 WorldView-2 Görüntüsü ve Gerçekleştirilen Ön İşlemler .....                 | 83         |
| 3.3.1 Radyometrik ve atmosferik düzeltmeler .....                               | 85         |
| 3.3.2 Geometrik düzeltmeler .....                                               | 92         |
| 3.3.3 Görüntü kaynaştırma .....                                                 | 93         |
| 3.4 Spektral Ölçümler ve Spektral Kütüphane Oluşturma Çalışmaları .....         | 95         |
| 3.4.1 Gerçekleştirilen saha çalışmaları .....                                   | 95         |
| 3.4.2 Spektroradyometre ölçümleri ve spektral özelliklerin analizi .....        | 97         |
| 3.4.3 Spektral kütüphanelerin oluşturulması .....                               | 104        |
| 3.5 Sınıflandırma Öncesi Gerçekleştirilen Ön Hazırlıklar .....                  | 108        |
| 3.5.1 Yardımcı verilerin oluşturulması .....                                    | 109        |
| 3.5.2 Arazi örtüsü sınıflarının ve örnekleme alanlarının tespiti .....          | 114        |
| 3.6 Özellik Seçimi ve Boyut İndirgeme .....                                     | 119        |
| <b>4. OBJE TABANLI SINIFLANDIRMA .....</b>                                      | <b>121</b> |
| 4.1 Görüntü Segmentasyonu .....                                                 | 122        |
| 4.2 Görüntü Objelerine Ait Özelliklerin Tanımlanması .....                      | 125        |
| 4.3 Eğitim ve Test Veri Setlerinin Oluşturulması .....                          | 126        |
| 4.4 Özellik (Bant) Seçimi ve Boyut İndirgeme .....                              | 126        |
| 4.5 Obje Tabanlı Sınıflandırma İçin Performans Analizi .....                    | 128        |
| 4.5.1 En yakın komşuluk algoritması ile obje tabanlı sınıflandırma .....        | 129        |
| 4.5.2 Karar ağaçları algoritması ile obje tabanlı sınıflandırma .....           | 131        |
| 4.5.3 Destek vektör makineleri ile obje tabanlı sınıflandırma .....             | 133        |
| 4.5.4 Rastgele orman sınıflandırıcısı ile obje tabanlı sınıflandırma .....      | 135        |
| 4.5.5 Torbalama algoritması ile obje tabanlı sınıflandırma .....                | 137        |
| 4.5.6 Hızlandırma algoritması ile obje tabanlı sınıflandırma .....              | 139        |
| 4.5.7 Çoklu hızlandırma yöntemiyle obje tabanlı sınıflandırma .....             | 141        |
| 4.5.8 Rotasyon orman algoritması ile obje tabanlı sınıflandırma .....           | 143        |
| <b>5. PİKSEL TABANLI SINIFLANDIRMA .....</b>                                    | <b>147</b> |
| 5.1 Eğitim ve Test Veri Setlerinin Oluşturulması .....                          | 148        |
| 5.2 Özellik (bant) Seçimi ve Boyut İndirgeme .....                              | 148        |
| 5.3 Piksel Tabanlı Sınıflandırma İçin Performans Analizi .....                  | 149        |



|                                                                                 |            |
|---------------------------------------------------------------------------------|------------|
| 5.3.1 En yakın komşuluk algoritması ile piksel tabanlı sınıflandırma.....       | 150        |
| 5.3.2 Karar ağaçları algoritması ile piksel tabanlı sınıflandırma .....         | 151        |
| 5.3.3 Destek vektör makineleri algoritması ile piksel tabanlı sınıflandırma ... | 153        |
| 5.3.4 Rastgele orman algoritması ile piksel tabanlı sınıflandırma .....         | 154        |
| 5.3.5 Torbalama algoritması ile piksel tabanlı sınıflandırma.....               | 156        |
| 5.3.6 Hızlandırma algoritması ile piksel tabanlı sınıflandırma .....            | 157        |
| 5.3.7 Çoklu hızlandırma yöntemiyle piksel tabanlı sınıflandırma .....           | 159        |
| 5.3.8 Rotasyon orman algoritması ile piksel tabanlı sınıflandırma.....          | 160        |
| <b>6. BULGULAR VE TARTIŞMA .....</b>                                            | <b>163</b> |
| 6.1 Veri Seti Boyutundaki Değişimlere Göre Performans Analizi .....             | 163        |
| 6.1.1 En yakın komşuluk algoritması.....                                        | 163        |
| 6.1.2 Karar ağaçları algoritması .....                                          | 165        |
| 6.1.3 Destek vektör makineleri algoritması .....                                | 167        |
| 6.1.4 Rastgele orman algoritması.....                                           | 169        |
| 6.1.5 Torbalama algoritması .....                                               | 170        |
| 6.1.6 Hızlandırma algoritması.....                                              | 172        |
| 6.1.7 Çoklu hızlandırma algoritması.....                                        | 173        |
| 6.1.8 Rotasyon orman algoritması .....                                          | 174        |
| 6.2 Sınıflandırma Algoritmalarının Karşılaştırılması ve Analizi .....           | 176        |
| 6.2.1 Obje tabanlı yaklaşım için performans analizi.....                        | 176        |
| 6.2.2 Piksel tabanlı yaklaşım için performans analizi.....                      | 179        |
| 6.2.3 Obje ve piksel tabanlı yaklaşımların karşılaştırılması ve analizi.....    | 181        |
| 6.3 Özellik Seçimi Algoritmalarının Karşılaştırılması ve Analizi .....          | 184        |
| 6.3.1 Özellik seçimi algoritmalarının karşılaştırılması ve analizi.....         | 185        |
| 6.3.2 Özellik seçimi ile belirlenen özelliklerin (bantların) analizi.....       | 188        |
| 6.3.3 Tematik harita Üretimi ve Doğruluk Analizi .....                          | 198        |
| <b>7. SONUÇ VE ÖNERİLER.....</b>                                                | <b>211</b> |
| <b>KAYNAKLAR .....</b>                                                          | <b>217</b> |
| <b>EKLER.....</b>                                                               | <b>231</b> |
| <b>ÖZGEÇMİŞ.....</b>                                                            | <b>245</b> |



## KISALTMALAR

|                |                                                                 |
|----------------|-----------------------------------------------------------------|
| <b>ARVI</b>    | : Atmosferik kořullara dayanıklı bitki indeksi                  |
| <b>ASD</b>     | : Analytical Spectral Devices                                   |
| <b>ÇH</b>      | : Çoklu Hızlandırma                                             |
| <b>ChiSq</b>   | : Ki-Kare istatistik testi                                      |
| <b>DN</b>      | : Digital Number                                                |
| <b>DVM</b>     | : Destek Vektör Makineleri                                      |
| <b>EMS</b>     | : Elektromanyetik Spektrum                                      |
| <b>EVI</b>     | : Geliştirilmiş bitki örtüsü indeksi                            |
| <b>EYK</b>     | : En Yakın Komşuluk                                             |
| <b>FCI</b>     | : Orman ve bitki indeksi                                        |
| <b>Fisher</b>  | : Fisher istatistik testi                                       |
| <b>GainR</b>   | : Kazanç Oranı                                                  |
| <b>GainR</b>   | : Kazanç Oranı                                                  |
| <b>GPS</b>     | : Global Positioning System                                     |
| <b>GS</b>      | : Gram-Schmidt                                                  |
| <b>GTÜ</b>     | : Gebze Teknik Üniversitesi                                     |
| <b>HIZ</b>     | : Hızlandırma                                                   |
| <b>IFOV</b>    | : Anlık Görüş Açısı                                             |
| <b>IHS</b>     | : Intensity-Hue-Saturation                                      |
| <b>InfG</b>    | : Bilgi Kazancı                                                 |
| <b>InfG</b>    | : Bilgi Kazancı                                                 |
| <b>KA</b>      | : Karar Ağaçları                                                |
| <b>MSAVI</b>   | : Düzenlenmiş toprak etkisi azaltılmış vejetasyon indeksi       |
| <b>NaiveB</b>  | : Naive Bayes                                                   |
| <b>NDSI</b>    | : Normalleştirilmiş toprak indeksi                              |
| <b>NDVI</b>    | : Normalized Difference Vegetation Index                        |
| <b>NDVI-1</b>  | : Normalleştirilmiş fark bitki örtüsü indeksi- 1                |
| <b>NDVI-2</b>  | : Normalleştirilmiş fark bitki örtüsü indeksi - 2               |
| <b>NDVI-3</b>  | : Normalleştirilmiş fark bitki örtüsü indeksi - 3               |
| <b>NHFD</b>    | : Homojen olmayan özellik farkı                                 |
| <b>NIR</b>     | : Yakın Kızılötesi                                              |
| <b>NIR1</b>    | : Yakın kızılötesi-1                                            |
| <b>NIR2</b>    | : Yakın kızılötesi-2                                            |
| <b>OSAVI</b>   | : Optimize edilmiş toprak etkisi azaltılmış vejetasyon indeksi  |
| <b>PCA</b>     | : Principal Component Analysis                                  |
| <b>PCABI</b>   | : Temel bileşen ve kızılötesi bant ile normalleştirilmiş indeks |
| <b>Pearson</b> | : Pearson Korelasyonu                                           |
| <b>ProbSig</b> | : Olasılıksal anlamlılık                                        |
| <b>ReliefF</b> | : Relief Fonksiyonu                                             |
| <b>RF</b>      | : Random Forest                                                 |
| <b>RTF</b>     | : Radyal tabanlı fonksiyon                                      |
| <b>RGB</b>     | : Red-Green-Blue                                                |
| <b>RO</b>      | : Rastgele Orman                                                |
| <b>RotOR</b>   | : Rotasyon Orman                                                |

|                |                                                                      |
|----------------|----------------------------------------------------------------------|
| <b>SAM</b>     | : Spectral Angle Mapping                                             |
| <b>SAVI</b>    | : Toprak etkisi azaltılmış vejetasyon İndeksi                        |
| <b>SFF</b>     | : Spectral Feature Fitting                                           |
| <b>SOM</b>     | : Self Organizing Map                                                |
| <b>DVM-ÖÖE</b> | : Özyinelemeli özellik eleme esasına dayalı destek vektör makineleri |
| <b>SWIR</b>    | : Orta Kızılötesi                                                    |
| <b>SymtUnc</b> | : Simetrik Belirsizlik                                               |
| <b>TB</b>      | : Temel Bileşen                                                      |
| <b>TRB</b>     | : Torbalama                                                          |
| <b>UTM</b>     | : Universal Transverse Mercator                                      |
| <b>WGS84</b>   | : World Geodetic System 1984                                         |
| <b>WV-2</b>    | : WorldView-2                                                        |

## ÇİZELGE LİSTESİ

### Sayfa

|              |                                                                                                                                             |     |
|--------------|---------------------------------------------------------------------------------------------------------------------------------------------|-----|
| Çizelge 2.1  | : Yardımcı veri seti olarak kullanılan doku özellikleri .....                                                                               | 39  |
| Çizelge 3.1  | : WorldView-2 uydusunun teknik özellikleri .....                                                                                            | 84  |
| Çizelge 3.2  | : WV-2 meta veri dosyasında radyometrik kalibrasyon ve etkili bant genişliği değerlerinin gösterimi .....                                   | 87  |
| Çizelge 3.3  | : WorldView-2 görüntüsü için spektral irradyans değerleri .....                                                                             | 88  |
| Çizelge 3.4  | : WV-2 meta veri dosyasında UTC zaman formatındaki görüntü kayıt zamanı verilerinin gösterimi .....                                         | 88  |
| Çizelge 3.5  | : WV-2 meta veri dosyasında ortalama güneş açısı gösterimi.....                                                                             | 89  |
| Çizelge 3.6  | : 2013 tarihli WV-2 uydu görüntüsüne ait kalibrasyon değerleri .....                                                                        | 91  |
| Çizelge 3.7  | : Kaynaştırma sonucu elde edilen görüntülere için hesaplanan entropi değerleri .....                                                        | 95  |
| Çizelge 3.8  | : Çalışma alanı içerisindeki ağaç türlerine ait bilgiler .....                                                                              | 96  |
| Çizelge 3.9  | : Çalışmada değerlendirmeye alınan vejetasyon indeksleri.....                                                                               | 109 |
| Çizelge 3.10 | : Yardımcı veri seti olarak kullanılan doku özellikleri .....                                                                               | 111 |
| Çizelge 3.11 | : Orman sınıfı içerisine dahil edilen ağaç türleri .....                                                                                    | 115 |
| Çizelge 3.12 | : Çalışma alanı için belirlenen arazi örtüsü ve arazi kullanım sınıfları .....                                                              | 118 |
| Çizelge 3.13 | : Özellik seçiminde kullanılan algoritmalar.....                                                                                            | 119 |
| Çizelge 4.1  | : Çoklu çözünürlük segmentasyonu işleminde kullanılan parametre değerleri ve obje sayıları .....                                            | 124 |
| Çizelge 4.2  | : Tek ölçek ve farklı ölçek parametreleri kullanılarak elde edilen genel sınıflandırma doğrulukları .....                                   | 125 |
| Çizelge 4.3  | : Obje tabanlı sınıflandırma işleminde dikkate alınan özellikler.....                                                                       | 125 |
| Çizelge 4.4  | : Sınıflandırmaya esas eğitim ve test verilerini oluşturan objelerin arazi örtüsü/kullanımı sınıflarına göre dağılımı .....                 | 126 |
| Çizelge 4.5  | : Obje tabanlı yaklaşımda elde edilen sınıflandırma doğruluklarının özellik seçimi algoritmaları ve bant sayıları açısından analizi .....   | 145 |
| Çizelge 5.1  | : Sınıflandırmaya esas eğitim ve test verilerini oluşturan piksellerin arazi örtüsü/kullanımı sınıflarına göre dağılımı .....               | 148 |
| Çizelge 5.2  | : Piksel tabanlı yaklaşımda elde edilen sınıflandırma doğruluklarının özellik seçimi algoritmaları ve bant sayıları açısından analizi ..... | 162 |
| Çizelge 6.1  | : Obje tabanlı yaklaşımda özellik seçimi algoritmalarının ve optimum bant sayılarının analizi.....                                          | 185 |
| Çizelge 6.2  | : Piksel tabanlı yaklaşımda özellik seçimi algoritmalarının ve optimum bant sayılarının analizi.....                                        | 186 |
| Çizelge 6.3  | : Obje tabanlı sınıflandırmada DVM-ÖÖE ile seçilen 50 özellik .....                                                                         | 190 |
| Çizelge 6.4  | : Piksel tabanlı sınıflandırmada DVM-ÖÖE ile seçilen 50 özellik ....                                                                        | 193 |
| Çizelge 6.5  | : Özellik seçimi algoritmaları tarafından tespit edilen en iyi 10 bant.                                                                     | 197 |
| Çizelge 6.6  | : RotOR algoritması için hesaplanan hata matrisi .....                                                                                      | 204 |
| Çizelge 6.7  | : DVM algoritması için hesaplanan hata matrisi .....                                                                                        | 206 |

|                                                                                                                                |     |
|--------------------------------------------------------------------------------------------------------------------------------|-----|
| <b>Çizelge 6.8</b> : Hata matrisleri yardımıyla hesaplanan kullanıcı ve üretici doğrulukları .....                             | 207 |
| <b>Çizelge 6.9</b> : $A_1$ ve $A_2$ sınıflandırıcıları için hesaplanan McNemar's hata matrisi.....                             | 208 |
| <b>Çizelge 6.10</b> : RotOR ve DVM algoritmaları için hesaplanan hata matrisi.....                                             | 209 |
| <b>Çizelge A.1</b> : Obje tabanlı sınıflandırmada DVM algoritması için belirlenen optimum parametre değerleri.....             | 236 |
| <b>Çizelge A.2</b> : Obje tabanlı sınıflandırmada HIZ, TRB ve RotOR algoritmaları için optimum iterasyon sayısı değerleri..... | 239 |
| <b>Çizelge A.3</b> : Obje tabanlı sınıflandırmada ÇH algoritması için belirlenen optimum parametre değerleri .....             | 242 |
| <b>Çizelge A.4</b> : Obje tabanlı sınıflandırmada RO algoritması için belirlenen optimum parametre değerleri .....             | 245 |

## ŞEKİL LİSTESİ

### Sayfa

|            |                                                                                                                                                                                                                |     |
|------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| Şekil 1.1  | : Tez kapsamında takip edilen iş akış diyagramı.....                                                                                                                                                           | 9   |
| Şekil 2.1  | : Elektromanyetik dalgalar .....                                                                                                                                                                               | 21  |
| Şekil 2.2  | : Elektromanyetik spektrum .....                                                                                                                                                                               | 22  |
| Şekil 2.3  | : Enerji ve nesne etkileşimi .....                                                                                                                                                                             | 25  |
| Şekil 2.4  | : Çınar ( <i>Platanus orientalis L.</i> ) ağacına ait spektral yansıma eğrisi .....                                                                                                                            | 27  |
| Şekil 2.5  | : Toprak ve su için genelleştirilmiş spektral yansıtım grafiği .....                                                                                                                                           | 28  |
| Şekil 2.6  | : Radyasyonun atmosferle etkileşimi .....                                                                                                                                                                      | 32  |
| Şekil 2.7  | : RGB ve HSI renk uzayları .....                                                                                                                                                                               | 41  |
| Şekil 2.8  | : Obje tabanlı sınıflandırmada temel işlem adımları .....                                                                                                                                                      | 47  |
| Şekil 2.9  | : Obje tabanlı sınıflandırmada a) satranç tahtası ve b) dörtlü ağaç tabanlı segmentasyon algoritmaları.....                                                                                                    | 48  |
| Şekil 2.10 | : Farklı ölçek parametreleri kullanılarak gerçekleştirilen segmentasyon işlemi .....                                                                                                                           | 51  |
| Şekil 2.11 | : En yakın komşuluk algoritması ile sınıflandırma problemi çözümü .....                                                                                                                                        | 54  |
| Şekil 2.12 | : Destek vektör makineleri ile iki sınıflı veri setinin sınıflandırılması.....                                                                                                                                 | 55  |
| Şekil 2.13 | : Ayrım yapılamayan veri setleri için hiperdüzlemler.....                                                                                                                                                      | 58  |
| Şekil 2.14 | : Doğrusal olarak ayrılamayan veri setlerinin DVM ile sınıflandırılması. ....                                                                                                                                  | 59  |
| Şekil 2.15 | : Üç sınıfa sahip dört bantlı veri seti için oluşturulan karar ağacı yapısı ..                                                                                                                                 | 61  |
| Şekil 2.16 | : Rastgele orman algoritmasının temel çalışma prensibi.....                                                                                                                                                    | 65  |
| Şekil 2.17 | : Rotasyon orman algoritmasının temel çalışma prensibi .....                                                                                                                                                   | 66  |
| Şekil 2.18 | : Özellik seçimi ve değerlendirilmesinde temel iş akışı .....                                                                                                                                                  | 70  |
| Şekil 2.19 | : Filtreleme algoritmalarının çalışma prensibi.....                                                                                                                                                            | 71  |
| Şekil 2.20 | : Sarmalama algoritmalarının çalışma prensibi.....                                                                                                                                                             | 71  |
| Şekil 2.21 | : OneR algoritmasının temel çalışma prensibi .....                                                                                                                                                             | 77  |
| Şekil 3.1  | : Çalışma alanı haritası, Kocaeli Gebze ilçesi .....                                                                                                                                                           | 81  |
| Şekil 3.2  | : Program başlangıç ekran görüntüsü .....                                                                                                                                                                      | 90  |
| Şekil 3.3  | : WV-2 görüntüsüne ait temel bilgilerin girildiği program ara yüzü .....                                                                                                                                       | 91  |
| Şekil 3.4  | : Kaynaştırma işlemi sonucunda elde edilen görüntüler. (a) Multispektral WV-2 görüntüsü (2m), (b) pankromatik WV-2 görüntüsü, (c) HSI dönüşümü, (d) Brovey dönüşümü, (e) PCA dönüşümü ve (f) GS dönüşümü ..... | 94  |
| Şekil 3.5  | : Spektral ölçümler için belirlenen örnekleme noktalarının dağılımı.....                                                                                                                                       | 97  |
| Şekil 3.6  | : Spektral kütüphane oluşturulmasında takip edilen temel işlem adımları....                                                                                                                                    | 98  |
| Şekil 3.7  | : ASD FieldSpec3 ile Sedir ağacına ait spektral özelliklerin belirlenmesi....                                                                                                                                  | 99  |
| Şekil 3.8  | : Geniş yapraklı ağaç türlerine ait ölçülen spektral yansıma eğrileri: a) Ayva; b) Karakavak; c) Ceviz; d) Zeytin ve e) Çınar .....                                                                            | 100 |
| Şekil 3.9  | : İğne yapraklı ağaç türlerine ait ölçülen spektral yansıma eğrileri: a) Fıstık Çamı; b) Kızılçam; c) Sedir ve d) Servi.....                                                                                   | 101 |
| Şekil 3.10 | : Geniş ve iğne yapraklı ağaç türlerine ait spektral yansıtım eğrileri.....                                                                                                                                    | 102 |

|                                                                                                                                   |     |
|-----------------------------------------------------------------------------------------------------------------------------------|-----|
| <b>Şekil 3.11 :</b> Spektral ölçümleri gerçekleştirilen ağaç türlerine ait spektral kütüphane .....                               | 104 |
| <b>Şekil 3.12 :</b> SFF algoritması ile elde edilen sonuçların grafiksel gösterimi .....                                          | 105 |
| <b>Şekil 3.13 :</b> WV-2 spektral bant aralığına ölçeklenen spektral kütüphane .....                                              | 107 |
| <b>Şekil 3.14 :</b> Sınıflandırma ve tematik harita üretiminde takip edilen işlem adımları .....                                  | 108 |
| <b>Şekil 3.15 :</b> Normalleştirilmiş fark bitki örtüsü indeksi .....                                                             | 110 |
| <b>Şekil 3.16 :</b> Temel bileşenler analizi sonucunda hesaplanan varyans değerleri .....                                         | 112 |
| <b>Şekil 3.17 :</b> Yardımcı veri olarak üretilen ilk temel bileşene ait tematik harita .....                                     | 113 |
| <b>Şekil 3.18 :</b> WV-2'nin kırmızı, yeşil ve mavi bantları kullanılarak hesaplanan ton bileşenine ait tematik harita .....      | 114 |
| <b>Şekil 3.19 :</b> Spektral açı haritalama algoritmasının temel çalışma prensibi .....                                           | 116 |
| <b>Şekil 3.20 :</b> İğne ve geniş yapraklı ağaç türleri için tespit edilen örnekleme alanları .....                               | 117 |
| <b>Şekil 4.1 :</b> Obje tabanlı sınıflandırmada temel işlem adımları .....                                                        | 121 |
| <b>Şekil 4.2 :</b> Farklı ölçek parametrelerinin belirlendiği bölgeler .....                                                      | 123 |
| <b>Şekil 4.3 :</b> Özellik seçimi işleminde takip edilen işlem adımları .....                                                     | 127 |
| <b>Şekil 4.4 :</b> Özellik seçimi ile ilgili önerilen yaklaşım .....                                                              | 128 |
| <b>Şekil 4.5 :</b> Obje tabanlı yaklaşımda farklı boyutta veri setleri için EYK algoritmasının sınıflandırma performansı .....    | 130 |
| <b>Şekil 4.6 :</b> Obje tabanlı yaklaşımda farklı boyutta veri setleri için KA algoritmasının sınıflandırma performansı .....     | 132 |
| <b>Şekil 4.7 :</b> Obje tabanlı yaklaşımda farklı boyutta veri setleri için DVM algoritmasının sınıflandırma performansı .....    | 134 |
| <b>Şekil 4.8 :</b> Obje tabanlı yaklaşımda farklı boyutta veri setleri için RO algoritmasının sınıflandırma performansı .....     | 136 |
| <b>Şekil 4.9 :</b> Obje tabanlı yaklaşımda farklı boyutta veri setleri için TRB algoritmasının sınıflandırma performansı .....    | 138 |
| <b>Şekil 4.10 :</b> Obje tabanlı yaklaşımda farklı boyutta veri setleri için HIZ algoritmasının sınıflandırma performansı .....   | 140 |
| <b>Şekil 4.11 :</b> Obje tabanlı yaklaşımda farklı boyutta veri setleri için ÇH algoritmasının sınıflandırma performansı .....    | 142 |
| <b>Şekil 4.12 :</b> Obje tabanlı yaklaşımda farklı boyutta veri setleri için RotOR algoritmasının sınıflandırma performansı ..... | 144 |
| <b>Şekil 5.1 :</b> Piksel tabanlı sınıflandırma yaklaşımında temel işlem adımları .....                                           | 147 |
| <b>Şekil 5.2 :</b> Özellik seçimi işleminde takip edilen işlem adımları .....                                                     | 149 |
| <b>Şekil 5.3 :</b> Piksel tabanlı yaklaşımda farklı boyutta veri setleri için EYK algoritmasının sınıflandırma performansı .....  | 151 |
| <b>Şekil 5.4 :</b> Piksel tabanlı yaklaşımda farklı boyutta veri setleri için KA algoritmasının sınıflandırma performansı .....   | 152 |
| <b>Şekil 5.5 :</b> Piksel tabanlı yaklaşımda farklı boyutta veri setleri için DVM algoritmasının sınıflandırma performansı .....  | 154 |
| <b>Şekil 5.6 :</b> Piksel tabanlı yaklaşımda farklı boyutta veri setleri için RO algoritmasının sınıflandırma performansı .....   | 155 |
| <b>Şekil 5.7 :</b> Piksel tabanlı yaklaşımda farklı boyutta veri setleri için TRB algoritmasının sınıflandırma performansı .....  | 157 |
| <b>Şekil 5.8 :</b> Piksel tabanlı yaklaşımda farklı boyutta veri setleri için HIZ algoritmasının sınıflandırma performansı .....  | 158 |
| <b>Şekil 5.9 :</b> Piksel tabanlı yaklaşımda farklı boyutta veri setleri için ÇH algoritmasının sınıflandırma performansı .....   | 159 |



|                     |                                                                                                                 |     |
|---------------------|-----------------------------------------------------------------------------------------------------------------|-----|
| <b>Şekil 5.10 :</b> | Piksel tabanlı yaklaşımda farklı boyutta veri setleri için RotOR algoritmasının sınıflandırma performansı ..... | 161 |
| <b>Şekil 6.1 :</b>  | Obje tabanlı yaklaşımda EYK algoritmasının özellik boyutu değişimine göre sınıflandırma performansı .....       | 164 |
| <b>Şekil 6.2 :</b>  | Piksel tabanlı EYK algoritmasının özellik boyutu değişimine göre sınıflandırma performansı .....                | 165 |
| <b>Şekil 6.3 :</b>  | Obje tabanlı KA algoritmasının özellik boyutu değişimine göre sınıflandırma performansı .....                   | 166 |
| <b>Şekil 6.4 :</b>  | Piksel tabanlı KA algoritmasının özellik boyutu değişimine göre sınıflandırma performansı .....                 | 166 |
| <b>Şekil 6.5 :</b>  | Obje tabanlı DVM algoritmasının özellik boyutu değişimine göre sınıflandırma performansı .....                  | 167 |
| <b>Şekil 6.6 :</b>  | Piksel tabanlı DVM algoritmasının özellik boyutu değişimine göre sınıflandırma performansı .....                | 168 |
| <b>Şekil 6.7 :</b>  | Obje tabanlı RO algoritmasının özellik boyutu değişimine göre sınıflandırma performansı .....                   | 169 |
| <b>Şekil 6.8 :</b>  | Piksel tabanlı RO algoritmasının özellik boyutu değişimine göre sınıflandırma performansı .....                 | 170 |
| <b>Şekil 6.9 :</b>  | Obje tabanlı torbalama algoritmasının özellik boyutu değişimine göre sınıflandırma performansı .....            | 171 |
| <b>Şekil 6.10 :</b> | Piksel tabanlı torbalama algoritmasının özellik boyutu değişimine göre sınıflandırma performansı .....          | 171 |
| <b>Şekil 6.11 :</b> | Obje tabanlı hızlandırma algoritmasının özellik boyutu değişimine göre performansı .....                        | 172 |
| <b>Şekil 6.12 :</b> | Piksel tabanlı hızlandırma algoritmasının özellik boyutu değişimine göre performansı .....                      | 173 |
| <b>Şekil 6.13 :</b> | Obje tabanlı çoklu hızlandırma algoritmasının özellik boyutu değişimine göre performansı .....                  | 173 |
| <b>Şekil 6.14 :</b> | Piksel tabanlı çoklu hızlandırma algoritmasının özellik boyutu değişimine göre performansı .....                | 174 |
| <b>Şekil 6.15 :</b> | Obje tabanlı RotOR algoritmasının özellik boyutu değişimine göre sınıflandırma performansı .....                | 175 |
| <b>Şekil 6.16 :</b> | Piksel tabanlı RotOR algoritmasının özellik boyutu değişimine göre sınıflandırma performansı .....              | 176 |
| <b>Şekil 6.17 :</b> | Obje tabanlı yaklaşım kullanılarak elde edilen sınıflandırma sonuçları .....                                    | 178 |
| <b>Şekil 6.18 :</b> | Piksel tabanlı yaklaşım kullanılarak elde edilen sınıflandırma sonuçları .....                                  | 180 |
| <b>Şekil 6.19 :</b> | WV-2 uydu görüntüsü kullanılarak hesaplanan sınıflandırma doğrulukları .....                                    | 181 |
| <b>Şekil 6.20 :</b> | WV-2 ve yardımcı veri setleri kullanılarak hesaplanan sınıflandırma doğrulukları .....                          | 182 |
| <b>Şekil 6.21 :</b> | Özellik seçimi ile belirlenen veri setleri için hesaplanan sınıflandırma doğrulukları .....                     | 183 |
| <b>Şekil 6.22 :</b> | Obje ve piksel tabanlı sınıflandırmada özellik seçimi algoritmaların kullanım sıklığının analizi .....          | 187 |
| <b>Şekil 6.23 :</b> | Obje ve piksel tabanlı sınıflandırmada özellik boyutunun analizi .....                                          | 188 |
| <b>Şekil 6.24 :</b> | Obje tabanlı sınıflandırmada seçilen özelliklerin kullanılan bantlar açısından analizi .....                    | 191 |

|                                                                                                                    |     |
|--------------------------------------------------------------------------------------------------------------------|-----|
| <b>Şekil 6.25 :</b> Piksel tabanlı sınıflandırmada seçilen özelliklerin kullanılan bantlar açısından analizi ..... | 195 |
| <b>Şekil 6.26 :</b> Obje ve piksel tabanlı sınıflandırmada kullanılan bantların analizi .....                      | 196 |
| <b>Şekil 6.27 :</b> RotOR algoritması ile üretilen tematik harita .....                                            | 199 |
| <b>Şekil 6.28 :</b> DVM algoritması ile üretilen tematik harita .....                                              | 200 |
| <b>Şekil 6.29 :</b> Tematik haritaların karşılaştırılması.....                                                     | 202 |

# **YÜKSEK ÇÖZÜNÜRLÜKLÜ UYDU GÖRÜNTÜLERİ KULLANARAK BENZER SPEKTRAL ÖZELLİKLERE SAHİP DOĞAL NESNELERİN AYIRT EDİLMESİNE YÖNELİK BİR METODOLOJİ GELİŞTİRME**

## **ÖZET**

Yeryüzü özelliklerinin çeşitliliği ve konumsal olarak dağılımı ile ilgili güvenilir ve doğru bilgilerin elde edilmesi birçok uygulama için esastır. Yeryüzünün çeşitli konumsal ve spektral çözünürlüklerde görüntülenmesinde etkili bir araç olan uzaktan algılama teknolojileri, yeryüzü ile ilgili değerli bilgilerin elde edilmesinde uzun yıllardır kullanılmaktadır. Söz konusu teknolojiler özellikle geniş alanların görüntülenmesi ve analizinde etkin ve ekonomik çözümler sunmaktadır. Uzaktan algılama uyduları ve algılayıcı tasarımıyla yaşanan teknolojik gelişmeler, çevresel görüntüleme ve doğal kaynak yönetimini de içerisine alan birçok konuda yeni araştırma olanakları ortaya çıkarmıştır. Yeni nesil algılayıcı sistemler aracılığıyla elde edilen görüntüler, yeryüzü nesnelerinin niteliği, özellikleri ve dağılımları hakkında çok daha detaylı bilgiler sağlamaktadır. Orta çözünürlüklü uydu görüntülerinin aksine, yüksek çözünürlüklü uydu görüntüleri üzerinden ağaçlar ve binalar gibi tekil yüzey nesnelerinin görsel olarak yorumlanması kolaylaşarak, nesnelerin birbirlerinden ayırt edilebilmesi mümkün hale gelmiştir. Kullanıcılara sağladığı önemli avantajlar nedeniyle son yıllarda yüksek çözünürlüklü uydu görüntülerine olan ilgi artış göstermiş ve dijital görüntü işleme teknikleriyle görüntüler üzerinden benzer spektral özelliklere sahip türlerin ayırt edilmesi ve tekil yeryüzü nesnelerinin sınıflandırılması uzaktan algılama alanında önemli bir araştırma konusu olarak ortaya çıkmıştır.

Uydu görüntülerinin üzerinden yeryüzü nesnelere ilişkin bilgi çıkarımında en çok tercih edilen ve en etkili yöntem görüntü sınıflandırmadır. Sınıflandırma işleminin sonucunda yeryüzünün farklı özelliklerini gösteren tematik haritalar üretilmektedir. Elde edilen haritaların doğruluğu ve güvenilirliği uygulamaların başarısı açısından büyük önem taşımaktadır. Yüksek çözünürlüklü uydu görüntüleri kullanımı, dijital görüntü verilerinin yorumlanması ve analizinde önemli problemler ortaya çıkarmıştır. Yüksek konumsal çözünürlüklü verilerde komşu pikseller arasındaki spektral benzerlik nedeniyle karışık piksellerin oranının artması bunlardan en önemlisidir. Bununla birlikte, arazi örtüsü tiplerini temsil eden sınıfların kendi içerisinde ve birbirleri arasındaki yüksek spektral benzerlik nedeniyle görüntü üzerinden bilgi çıkarımı veya sınıflandırma işlemi karmaşık bir hal almaktadır. Söz konusu problemler nedeniyle yüksek çözünürlüklü uydu görüntüleriyle doğruluğu yüksek tematik harita üretiminde geleneksel sınıflandırma tekniklerinin yetersiz kaldığı ifade edilmektedir. Bu nedenle yüksek çözünürlüklü görüntülerin işlenmesi ve bilgi çıkarımında yeni ve etkili analiz tekniklerine ihtiyaç duyulmaktadır.

Bu tez çalışmasının temel amacı yüksek çözünürlüklü WorldView-2 (WV-2) uydu görüntüsü kullanılarak benzer spektral özelliklere sahip doğal nesnelerin sınıflandırılmasına yönelik bir metodoloji geliştirmektir. Bu amaca yönelik olarak

ön işleme, sınıflandırma ve tematik harita üretimini içeren görüntü sınıflandırma aşamaları kapsamlı bir biçimde ele alınmış, geleneksel tekniklerinin yanında ileri sınıflandırma yaklaşımları ve güncel sınıflandırma algoritmaları değerlendirmeye alınmıştır.

Çalışma sonucunda tez kapsamında ele alınan sınıflandırma probleminin çözümüne yönelik önemli bulgulara ulaşılmıştır. Bunlardan ilki, elde edilen sonuçlar geleneksel sınıflandırma yaklaşımlarının, doğal nesneler arasındaki spektral ayırımın gerçekleştirilmesi noktasında yetersiz kaldığını ve yüksek çözünürlüklü uydu görüntülerinin sınıflandırılması için uygun olmadığını göstermektedir. Geleneksel piksel tabanlı yaklaşımla karşılaştırıldığında, obje tabanlı sınıflandırma yaklaşımı kullanımıyla tematik harita doğruluğunda %8'e varan artışlar olduğu belirlenmiştir. İkinci olarak, sınıflandırma sonuçları, ileri sınıflandırma algoritmaları olarak adlandırılan destek vektör makineleri ve rotasyon orman algoritmalarının hem piksel hem de obje tabanlı yaklaşımda klasik en yakın komşuluk sınıflandırıcısı ve diğer öğrenme algoritmalarından daha üstün bir sınıflandırma performansı sergilediğini açık bir şekilde ortaya koymaktadır. Bu nedenle obje tabanlı sınıflandırma işleminin gerçekleştirilmesinde söz konusu sınıflandırma algoritmalarının tercih edilmesi önerilmiştir. Üçüncü olarak, tez kapsamında değerlendirmeye alınan ağaç türlerinin spektral karakteristiklerinin analizleri neticesinde, iğne ve geniş yapraklı ağaç türlerinin özellikle kırmızı bölgede birbirinden farklı spektral yansımalarla sahip olduğu görülmüştür. Arazide gerçekleştirilen spektral ölçüler ve uydu görüntüsünün ilişkilendirilmesi sonucunda, WV-2 görüntüsünün kırmızı kenar, yakın kırmızı-1 ve yakın kırmızı-2 bantlarının iğne ve geniş yapraklı ağaçların birbirinden ayırt edilmesi noktasında önemli spektral bilgiler sağladığı belirlenmiştir. Buna karşın, iğne ve geniş yapraklı ağaçları temsil eden sınıflar içerisindeki ağaç türleri arasındaki yüksek spektral benzerlik nedeniyle, WV-2 görüntüsü spektral olarak benzer ağaç türlerinin (örneğin sedir ve servi) ayırt edilmesi noktasında sınırlı seviyede bilgi sağladığı tespit edilmiştir. Bu nedenle, tematik harita doğruluğunun artırılması için sadece WV-2 görüntüsünün multispektral bantlarının kullanılması yerine, vejetasyon indeksleri, doku özellikleri ve temel bileşenler gibi yardımcı veri setlerinin değerlendirilmeye alınması gerekmektedir. Sınıflandırma sonuçları analiz edildiğine, yardımcı veri setleri kullanımıyla sınıflandırma doğruluğunda %8'lere varan seviyelerde artış olduğu görülmüştür. Dördüncü olarak, tez kapsamında değerlendirmeye alınan tüm sınıflandırma algoritmalarının boyutsallık veya Hughes fenomeninden etkilendiği tespit edilmiştir. Bu açıdan ele alındığında optimum özellik seti boyutunun tespit edilmesi sınıflandırma işleminin başarısı açısından kritik bir öneme sahiptir. Çalışma sonuçları yüksek boyutlu veri setini temsil eden daha az sayıda ve seçilen özellikleri içeren veri setleri kullanılması durumunda sınıflandırma doğruluğunun önemli derecede arttığını göstermektedir. Bu nedenle, yüksek boyutlu veri seti kullanımında ön yinelemeli özellik seçimi esasına dayalı destek vektör makineleri gibi uygun bir özellik seçimi algoritması dikkate alınmalıdır.

# **DEVELOPING A METHODOLOGY FOR DISCRIMINATING NATURAL OBJECTS HAVING SPECTRALLY SIMILAR FEATURES USING VERY HIGH RESOLUTION SATELLITE IMAGERY**

## **SUMMARY**

Obtaining reliable and accurate information about the Earth's surface features in terms of their quantity, diversity and spatial distribution is essential for a wide range of applications. Remote sensing technologies offering an efficient tool for monitoring the Earth's surface in various spatial and spectral resolutions have long been used for gathering this valuable information. It provides powerful and cost-effective solution in particular to visualization and analysis of large study areas. The latest technological innovations in the design of remote sensing satellites and sensors offer new application opportunities in many fields including environmental monitoring and natural resource management. Satellite imageries acquired by these systems introduce more detailed information about the nature, properties and distribution of the Earth's surface objects. Unlike moderate-resolution satellite imageries, individual surface objects, such as trees and buildings are visible in high resolution imagery. This important feature provides opportunities to differentiate spectrally similar species and mapping individual surface objects.

Image classification is the most preferred and effective method for the interpretation of satellite imageries. Thematic maps representing different characteristics of the Earth's surface are produced as a result of the classification process. The accuracy and reliability of the thematic maps have great importance for success of the applications. The use of high resolution imagery poses some important challenges in analyzing and interpreting of digital image data. One is that with higher spatial resolution data the percentage of mixed pixels is increased because of the spectral similarity between adjacent pixels. In addition, due to the high degree of within-class and between-class spectral similarity of land cover units, information extraction or classification process becomes more complex. For these reasons, traditional classification techniques have been reported to be insufficient for producing accurate thematic maps using high resolution images. Therefore, novel and efficient analysis techniques are required for processing and analyzing such images.

The overall aim of this thesis is to develop a methodology for classifying natural objects having spectrally similar features using high resolution WorldView-2 (WV-2) satellite imagery. For this purpose, image classification stages including pre-processing, classification and thematic mapping were comprehensively investigated in order to determine the most effective classification model for the particular classification problem considered in this thesis study.

The dissertation starts with introduction part including problem definition, the purpose of the research, followed by methodology and extensive literature review.

In the second part, general information about the basic principles of remote sensing including electromagnetic spectrum and electromagnetic energy, energy interaction with the atmosphere and the Earth's surface materials and spectral signature of surface features were described. Some image preprocessing techniques, such as corrections for radiometric, atmospheric and geometric effects were also presented. In addition, image transformations and the most popular transformation techniques (i.e. vegetation indices, textural features, principal component analysis, and Hue-Saturation-Intensity transformation) were given. Moreover, the detailed information about the image classification including supervised and unsupervised techniques, traditional pixel-based and object-based approaches, advanced classification algorithms namely, support vector machines, decision trees, ensemble learning algorithms including boosting, bagging, multi-boosting, random forest and rotation forest were discussed. At the end of this part, feature selection techniques were summarized and the several filter and wrapper based feature selection algorithms were discussed.

The application part of the thesis was discussed under three sub-sections. In the first sub-section (Section 3), WV-2 satellite imagery and related pre-processing operations (radiometric, atmospheric and geometric corrections), study area and field applications including spectral measurements with a field spectroradiometer and analysis of spectral features of measured tree types were explained in detail. In addition, several pansharpening algorithms (i.e. HSI, PCA, Brovey and Gram Schmidt) were assessed to investigate fusion of a high spatial resolution panchromatic image with lower spatial resolution multispectral images of WV-2. Besides the preprocessing of satellite imagery and field applications, preparation of auxiliary data sets (i.e. vegetation indices, HSI transformations, principal components and textural features) were presented. Finally, land use/land cover types and sampling regions, the main inputs for the classification process, were determined by means of the spectral measures and atmospherically corrected WV-2 imagery.

The second sub-section of application part (Section 4) addresses the object based classification and related processes. This section consisted of image segmentation, describing image object features, creating training and testing data sets, feature selection and object based classification. Region-based scale parameter selection was suggested and applied to perform image segmentation. Moreover, for the selection of relevant features and defining optimum feature size, 13 feature selection algorithms were applied to the high dimensional data containing variety of spectral and textural features of image objects. Data sets of different sizes formed by the feature selection results were used for the object based classification. Also the traditional nearest neighbor algorithm and advanced classification algorithms were applied to these data sets and their classification performances were analyzed thoroughly.

The final sub-section (Section 5) focuses on the traditional pixel based classification method. To make objective comparison, training and testing data sets were determined in accordance with the data sets considered in object based classification. Feature selection algorithms were employed to the high dimensional data to produce new data sets having smaller number of spectral features. Pixel based classification was performed using these data sets formed by the feature selection results and the performances of classification algorithms were analyzed in detail.

The results and discussion part of the dissertation (Section 6) includes detailed and comparative analysis of the application results, such as comparison of classification approaches and algorithms in terms of their use and performances, analysis of the effective features and optimum feature set size, thematic map producing and exploring the map accuracy.

All in all, some important conclusions can be drawn from the results produced in this dissertation. First, the application presented in this thesis demonstrated that the conventional classification approaches were not suitable for the classification of high resolution satellite imagery as they found to be insufficient for spectral separability of natural objects. When the classification performances were compared, it was found that with the use of object based classification approaches, improvements in thematic map accuracy reached to 8%. Secondly, the results noticeably indicated that support vector machine and rotation forest ensemble learning algorithms outperformed the traditional nearest neighbor classifier and the other learning algorithms in both pixel based and object based classifications. Therefore, these two outperforming algorithms were preferred classification algorithm to perform accurate object based classification. Thirdly, from the analysis of measured spectral characteristics of tree species considered in this thesis, it was revealed that deciduous and coniferous trees have distinct spectral reflectance especially in near infrared region. As a result of the integration of the field-based spectral measurements and satellite imagery it was observed that red edge, near infrared-1 and near infrared-2 bands of WV-2 imagery provides valuable spectral information to differentiate between deciduous and coniferous trees. However, due to the high degree of within-class spectral similarity, multispectral bands of WV-2 image were found to be limited for differentiate spectrally similar tree types (e.g. Cedar and Cupressus trees). For this reason, instead of using only multispectral bands of WV-2 imagery, auxiliary data such as vegetation indices, textural features and principal components should be taken into consideration to increase the accuracy of the thematic maps. When the classification results were analyzed it was observed that the use of auxiliary data led to a clear increase in classification accuracy up to 8%. Fourthly, results showed that a reduction of high dimensional data to a few but specifically selected features also improve the classification accuracies. For this reason, a suitable feature selection algorithm such as SVM-RFE should be considered when high dimensional data were considered. Another important finding was that the all classification algorithms were affected by the curse of dimensionality or Hughes phenomenon. Thus, determination of optimum feature set size was also critical for the success of classification.





## 1. GİRİŞ

Yeryüzü ile ilgili yapılan çalışmaların başarısı kullanılacak bilginin doğruluğu ve güvenilirliği ile yakından ilişkilidir. Bununla birlikte söz konusu bilgilerin hızlı ve ekonomik bir şekilde elde edilebilmesi önemli bir ihtiyaçtır. Geçmişten günümüze kadar ekosistem içerisindeki doğal nesnelerin ya da ekosistemi oluşturan türlerin çeşitliliğinin belirlenmesi ve kayıt altına alınması önemli bir araştırma konusu olmuştur (He ve Legendre, 2002). Son yıllarda küresel boyutta gerçekleşen çevresel ve iklim değişiklikleri nedeniyle tür çeşitliliğinin azalması ve endemik bitki türlerinin yok olma tehlikesiyle karşı karşıya kalması nedeniyle sürdürülebilir çevre ve ekolojik çeşitliliğin korunması açısından söz konusu araştırmalar büyük önem kazanmıştır. Bu nedenle iklim değişikliklerinin, habitat değişimlerinin ve insan aktivitelerinin ekosistem oluşumu ve fonksiyonu üzerindeki etkilerinin değerlendirilmesi ve analizi açısından biyoçeşitliliğin haritalanmasına yönelik operasyonel yaklaşımların ortaya konulması artan bir ihtiyaçtır (Feret ve Asner, 2014).

Özellikle ağaç türlerinin belirlenmesi ve haritalanması orman ekosistemi tanımlanmasında önemli bir parametredir (Reedy ve diğ., 2014). Orman kapalılığını oluşturan ağaç türleri ve ağaç sayısı, biyoçeşitlilik ve habitat kalitesi gibi orman alanlarının ekolojik değerini tanımlayan önemli göstergelerden oluşan ekolojik parametrelerle yakından ilişkilidir (Forster ve diğ., 2008). Bununla birlikte, ağaç türlerinin dağılımına ilişkin bilgiler ormanlardan faydalanma ve orman yönetimine ilişkin etkili politikalar üretilmesi açısından önemli bir veri kaynağı olduğundan, ağaç türleri dağılımının yüksek doğrulukta belirlenmesi orman ekosistemlerinin sürdürülebilir yönetimi için büyük önem taşımaktadır (Fassnacht ve diğ., 2014). Geleneksel orman envanteri elde etme yöntemleri ve diğer saha bazlı veri elde etme yaklaşımları, örneğin ağaç kapalılığı veya ağaç türlerinin belirlenmesi için uygun bir yöntem değildir. Saha çalışmaları ile çok geniş alanlar içerisindeki ağaç türleri hakkında bilgi toplamak oldukça zordur. Bu nedenle ağaç türleri ile ilgili konumsal olarak ağaç türlerinin belirlenmesi ve ayırt edilmesi noktasında gelişmiş yöntem ve yaklaşımlara ihtiyaç duyulmaktadır (Immitzer, 2012). Özellikle geniş alanları

kaplayan orman alanlarının tespiti, haritalanması ve yönetimi için geleneksel yöntemlere alternatif teknoloji destekli sistemlerin geliştirilmesi büyük önem taşımaktadır.

Pratikte, arazi çalışmaları ve hava fotoğraflarının yorumlanması ağaç örtüsü ile ilgili bilgi ediniminde kullanılan iki geleneksel yöntemdir. Arazide gerçekleştirilen envanter toplama çalışmaları yüksek zaman, maliyet ve iş gücü gerektirmekte bununla birlikte özellikle geniş alanlar söz konusu olduğunda arazi çalışmalarını gerçekleştirmek oldukça zorlaşmaktadır. Aynı şekilde büyük ölçekte ağaç türlerinin haritalanmasında hava fotoğraflarının yorumlanması da zaman gerektiren pahalı bir yöntemdir. Arazi çalışmalarının gerçekleştirilmesinde yaşanan bu zorluklar uzaktan algılama teknolojilerinin kullanımıyla aşılabilmekte, çok geniş alanlara ait bitki örtüsünün haritalanması hatta bitki türlerinin birbirinden ayırt edilmesi noktasında uydu görüntülerinin kullanımı önemli avantajlar sağlayabilmektedir. Cisimlerle direkt temas etmeden fiziksel özellikleri hakkında bilgi elde etme bilimi olarak tanımlanan uzaktan algılama tekniği ile yeryüzünün farklı konumsal, spektral, radyometrik ve zamansal çözünürlüklerde görüntülenmesi ve izlenmesi mümkün olabilmektedir. Sahip olduğu bu önemli özellikler, uzaktan algılama teknolojilerini yeryüzünde meydana gelen yapay ve doğal değişikliklerin izlenmesi, mevcut doğal kaynaklara ilişkin envanterlerin oluşturulması gibi küresel veya yerel ölçekli birçok çalışma için önemli bir araç durumuna getirmiştir.

Uzaktan algılama teknolojilerinin kullanıldığı en önemli uygulama alanlarından birisi de uydu görüntüleri yardımıyla arazi örtüsü ve/veya arazi kullanımının belirlenerek yeryüzünü temsil eden tematik haritaların üretilmesidir. Arazi örtüsü ve/veya kullanımının belirlenmesi gerek planlama gerekse doğal çevrenin korunması açısından son derece önemlidir. Son yıllarda uzaktan algılama teknolojileri ve uydu algılayıcıları tasarımında yaşanan gelişmeler beraberinde uzaktan algılama alanında yeni araştırma konularının ortaya çıkmasına neden olmuştur. Özellikle yüksek çözünürlüğe sahip uydu görüntülerinin varlığı ile birlikte yeryüzü nesnelere ilişkin gerek konumsal gerekse spektral açıdan daha detaylı bilgiler elde edilebilmektedir. Söz konusu görüntüler başta detaylı arazi örtüsü veya kullanımının haritalanması olmak üzere benzer spektral özelliklere sahip doğal ve yapay nesnelerin birbirinden ayırt edilmesi amacıyla kullanılabilmektedir.

## 1.1 Problem Tanımı

Yeryüzü üzerindeki nesnelerin uzaktan algılama teknolojileri ile ayırt edilebilmelerinin en önemli nedeni söz konusu nesnelerin farklı spektral özelliklere sahip olmasıdır. Uzaktan algılama sistemleri, seçilen dalga boyu bantlarında yer yüzeyindeki cisimlerden yansıyan ve yayılan enerji miktarlarını kayıt etmektedir. Daha sonra elde edilen bu veriler yeryüzü üzerindeki objelerin yorumlanması ve analizi için kullanılmaktadır. Uzaktan algılanan verilerin bilgisayar ortamında analiz edilebilmesi için nesnelerin spektral özelliklerinin bilinmesi gerekmektedir. Bu nedenle çalışma sahasında yer alan bitki türlerinin, toprağın, suyun ve ilgilenilen diğer yer yüzeyi nesnelere ait spektral özelliklerinin tespiti, uzaktan algılanan verilerin uygun bir şekilde analizi ve yorumlanması açısından son derece önemlidir. Özellikle görünür ve kızılötesi bölgede benzer spektral özellikler sergileyen bitki türlerinin ayırt edilmesinde arazide gerçekleştirilecek spektral ölçümler büyük önem arz etmektedir. Spektral ölçümler sonucunda elde edilen bilgiler bir nesne türünün spektrumun hangi dalga boyu aralığında diğer nesne türlerinden farklı davranış gösterdiğinin belirlenmesinde önemli rol oynamaktadır. Spektral ölçümler sonucu farklı bitki türleri için spektral kütüphaneler oluşturulmakta ve uydu görüntüleri üzerindeki karışık piksellerin ayırt edilmesi gibi problemlerin çözümünde başarıyla kullanılmaktadır. Bu bağlamda farklı nesne türleri için spektral kütüphanelerin oluşturulması uydu görüntüsünün sınıflandırılmasında ve doğruluğu yüksek tematik harita üretiminde önemli bir altlık niteliğindedir.

Son birkaç yıla kadar düşük konumsal ve spektral çözünürlüğü nedeniyle orta-çözünürlüklü uzaktan algılanmış görüntüler özellikle meşcere durumu ve meşcere kapallılığının tespit edilmesi noktasında sınırlı bilgi sağlamıştır. Bununla birlikte söz konusu görüntüler ile ağaç türlerinin tespit edilerek haritalanmasını içeren detaylı çalışmaların gerçekleştirilmesi oldukça güçtür. Son yıllarda uzaktan algılama algılayıcıları tasarımında yaşanan gelişmelere paralel olarak hem spektral hem de konumsal çözünürlüğü yüksek uydu görüntülerinin mevcudiyeti söz konusu olmuştur. Orta çözünürlüklü uydu görüntülerinin aksine yüksek çözünürlüklü görüntüler üzerinde ağaç toplulukları yerine ağaçlar ayrı ayrı görüntülenebilmektedir. Günümüze kadar, yüksek çözünürlüklü uydu görüntüleri üzerinden orman tiplerinin ve ağaç türlerinin haritalanması yeterli spektral bilgi eksikliği nedeniyle istenilen doğrulukta gerçekleştirilememiştir. Örneğin, Carleer ve Wolff (2004) IKONOS

görüntüsü kullanarak homojen bir orman alanı içindeki 7 farklı ağaç türünün tespitinde %86 genel doğruluğa ulaşabilmiştir. Johansen ve Phinn (2006) IKONOS ve Landsat ETM+ görüntüleri ile Avusturalya'nın tropik alanlarında bulunan 6 farklı ağaç türünün haritalanmasında tatmin edici sonuçlara ulaşamadıklarını ifade etmişlerdir. Katoh (2004) iğne yapraklı ve geniş yapraklı ağaçların bir arada bulunduğu heterojen orman topluluğu içindeki 14 ağaç türünün tespit edilmesi ve haritalanması probleminin çözümünde IKONOS uydu görüntüsü kullanarak ancak %62 genel doğruluğa ulaşabilmiştir.

Yüksek çözünürlüklü uydu görüntülerinin kullanımı yeryüzü ile ilgili detaylı bilgiler sağlamasına karşın, söz konusu detayların birbirinden ayırt edilmesi noktasında yeni problemler ortaya çıkarmıştır. Daha yüksek konumsal çözünürlük yeryüzü objelerine ilişkin çok daha detaylı bilgiler sağlamakla birlikte, artan detay seviyesi spektral anlamda yeryüzü objelerinin daha karmaşık bir hal almasına dolayısıyla birbirlerinden ayırt edilmeleri noktasında önemli bir problem olarak ortaya çıkmıştır (Myint ve diğ., 2011). Örneğin kentsel alan içerisindeki birçok arazi kullanım sınıfı (örneğin beton yollar, beton kaldırımlar, beton park alanları, beton çatı kaplamaları ve diğer parlak yeryüzü materyalleri) benzer veya aynı spektral özelliklere sahip olabilmektedir. Bu durum sadece spektral özellikleri dikkate alan geleneksel piksel-tabanlı yaklaşımların objelerin birbirinden ayırt edilmesi noktasında yetersiz kalmasına ve sınıflandırma doğruluğunun azalmasına neden olmaktadır. Bu nedenle yüksek çözünürlüklü görüntüler üzerinden karmaşık yapıdaki söz konusu piksellerin ayırt edilmesi noktasında yeni yaklaşım ve metotlara ihtiyaç duyulmaktadır.

Uydu görüntüleri üzerinden yeryüzü ile ilgili yararlı bilgilerin elde edilmesinde en sık kullanılan yöntem görüntülerin sınıflandırılmasıdır. Uydu görüntülerinin sınıflandırılması sonucunda yeryüzünün çeşitli özelliklerini gösteren tematik haritalar üretilmektedir. Söz konusu haritaların doğruluğu ve güvenilirliği birçok çalışma için kritik öneme sahiptir. Yüksek çözünürlüklü görüntülerin sınıflandırılmasında kullanılacak sınıflandırma yaklaşımının belirlenmesi üretilcek tematik haritaların doğruluğuna etki eden faktörlerden birisidir. Sınıflandırma işleminin gerçekleştirilmesinde genel olarak piksel tabanlı ve obje tabanlı kontrollü sınıflandırma yaklaşımları kullanılmaktadır. Yüksek çözünürlüklü görüntülerin sınıflandırılması ve tematik harita üretiminde söz konusu yaklaşımların sınıflandırma doğruluğuna etkileri son yıllarda öne çıkan araştırma konuları arasındadır. Örneğin,

yüksek çözünürlüklü görüntüler üzerinden ağaç türlerinin tespit edilmesinde yaşanan problemler arasında ağacın ışık alma farklılıkları, ağaç zeminindeki bitki örtüsünün ve gölge alanların etkisi geleneksel piksel-tabanlı sınıflandırma ile elde edilebilecek sınıflandırma doğruluğunu olumsuz olarak etkileyebilmektedir. Söz konusu problemin çözümü ve sınıflandırma doğruluğunun artırılması amacıyla yüksek çözünürlüklü uydu görüntülerinin sınıflandırılmasında obje tabanlı yaklaşımın kullanımı ön plana çıkmıştır. Obje tabanlı yaklaşımın daha yüksek sınıflandırma doğruluğu üretmesi üç temel neden ile açıklanabilir. Bunlardan ilki görüntünün benzer spektral özellikleri içeren piksellerden oluşan görüntü objelerine ayrılması. İkincisi sınıflandırma probleminin çözümünde sadece spektral özelliklerin kullanılması yerine doku ve kavramsal özelliklerin yanında, şekil ve geometrik özelliklerinde kullanılmasıdır. Üçüncü olarak ise ilgi duyulan yeryüzü nesnelerinin belirli bir görüntü üzerinden farklı ölçeklerde görüntülenebilmesidir.

Tematik harita üretiminde kullanılan sınıflandırma yaklaşımının belirlenmesi kadar sınıflandırma kullanılacak sınıflandırma algoritmasının seçimi de büyük önem taşımaktadır. Günümüze kadar uydu görüntülerinin sınıflandırılması ve tematik harita üretiminde birçok algoritma kullanılmış ve çeşitli derecelerde başarılar elde edilmiştir. Söz konusu algoritmalar istatistiksel tabanlı olanlar (en çok benzerlik, paralel kenar vb.) belirli istatistiksel kabullere dayalı işlem yapmakta dolayısıyla spektral ayrımın zor olduğu karışık pikselleri içeren görüntülerin sınıflandırılmasında ve sınırlı sayıda eğitim alanının belirlenebildiği problemlerin çözümünde düşük doğrulukta sonuçlar üretmektedir. Bu zayıflıkları ortadan kaldırmak amacıyla son dönemde daha güçlü sınıflandırma algoritmaları (yapay sinir ağları, karar ağaçları, destek vektör makineleri vb.) ile uydu görüntülerinin sınıflandırılması konusunda yoğun çalışmalar yürütülmektedir. Özellikle son yıllarda yüksek çözünürlüklü uydu görüntülerinin sınıflandırılması probleminin çözümünde ileri sınıflandırma algoritmalarının obje tabanlı sınıflandırma yaklaşımındaki performanslarının incelenmesi uzaktan algılama alanında önemli bir araştırma konusu olarak öne çıkmaktadır.

Literatürde yüksek çözünürlüklü uydu görüntüleri üzerinden benzer spektral özelliklere sahip nesnelerin ayırt edilmesinde uydu görüntüsünün mevcut spektral bantlarına ilave olarak nesneler arasındaki spektral ayrımın artırılması amacıyla çeşitli görüntü dönüşümleri sonucunda elde edilen yardımcı verilerin de

değerlendirmeye alındığı görülmektedir. Uydu görüntüleri ve yardımcı verilerin bir arada kullanılması durumunda yüksek boyutlu veri setinin sınıflandırılması problemi ortaya çıkmaktadır. Bunun temel nedeni yüksek boyutlu veri seti içerisinde sınıflandırma probleminin çözümüne fayda sağlamayan ya da birbirleriyle yüksek kolerasyona sahip bantların mevcut olmasıdır. Bununla birlikte yüksek boyutlu verilerle yapılan sınıflandırma işleminde boyutun artmasına paralel olarak belirli bir noktadan sonra sınıflandırma doğruluğunun düştüğü bilinmektedir. Yüksek boyutlu verilerde ortaya çıkan bu durum Hughes fenomeni veya boyutsallık (curse of dimensionality) kavramları ile açıklanmaktadır (Hughes,1968; Mianji ve Zhang, 2011). Bu nedenle söz konusu yüksek boyutlu verilerin değerlendirilmesi aşamasında hem işlem yükünün azaltılması hem de boyutsallık probleminin önüne geçilerek sınıflandırma doğruluğunun artırılması amacıyla özellik seçimi yoluna gidilmektedir. Literatürde özellik seçimine yönelik birçok algoritmanın geliştirildiği ve farklı uygulama alanlarında kullanıldığı görülmektedir. Söz konusu algoritmaların yüksek çözünürlüklü uydu görüntüleri ve yardımcı verileri içeren yüksek boyutlu veri setleri için kullanımlarının incelenmesi, hangi bantların veya özelliklerin sınıflandırma doğruluğuna etki ettiğinin tespiti, yüksek boyutlu veri setini temsil eden optimum bant (özellik) sayısının belirlenmesi ve sınıflandırma algoritmaların seçilen özelliklere göre performanslarının ortaya koyulması önemli araştırma konularıdır.

## **1.2 Çalışmanın Amacı**

Tez kapsamında, yüksek çözünürlüklü uydu görüntüleri üzerinden spektral olarak benzer özelliklere sahip bitki örtüsü tiplerinin ayırt edilmesi, sınıflandırılması ve haritalanması probleminin çözümüne yönelik bir yaklaşımın ortaya konulması amaçlanmaktadır. Bu genel amaç doğrultusunda tezin ana hedefleri:

- Yüksek konumsal ve spektral özelliğe sahip tek uydu olan WorldView-2 (WV-2) uydu görüntüsünün kullanımının incelenmesi,
- Ağaç türlerine ait spektral özelliklerin ölçülmesi, spektral özelliklerinin analizi ve spektral kütüphane oluşturulması,
- Uydu görüntüsü ile ilişkilendirilen spektral kütüphane yardımıyla sınıflandırma işlemine esas olacak örnekleme alanlarının tespiti,

- Görüntü dönüşümleri ile elde edilen yardımcı verilerin WV-2 görüntüsü ile birlikte kullanımı,
- Özellik seçiminde birçoğu uzaktan algılama alanında kullanımı yeni olan algoritmaların (filtreleme, sarmalama ve sezgisel) performans analizi,
- Özellik seçimi ile belirlenen en uygun bantların analizi ve incelenmesi,
- Obje ve piksel tabanlı yaklaşımın sınıflandırma performansının analizi,
- Geleneksel ve ileri sınıflandırma algoritmalarının piksel ve obje tabanlı yaklaşımda kullanımı ve performans analizi,
- Değerlendirmeye alınan sınıflandırma algoritmalarının özellik seçimi ile belirlenen farklı kombinasyonlardaki veri setleri için performans analizi,
- Değerlendirmeye alınan sınıflandırma algoritmalarının veri seti boyutu artışına göre performans analizi ve optimum veri seti boyutunun tespiti,
- Yüksek doğrulukta ve kalitede tematik harita üretimi,

şeklinde belirlenmiştir. Sonuç olarak yüksek çözünürlüklü uydu görüntüsü üzerinden doğal nesnelerin ayırt edilmesinde sınıflandırma ve tematik harita üretimi aşamaları çok yönlü olarak ele alınıp, ayrıntılı olarak analiz edilecek ve problem çözümünde yüksek tematik harita doğruluğu üreten optimum sınıflandırma modeli ortaya koyulacaktır.

### 1.3 Metodoloji

Tez kapsamında, spektral olarak benzer özelliklere sahip bitki örtüsü tiplerinin ayırt edilmesi ve söz konusu doğal nesnelerin sınıflandırılması probleminin çözümüne yönelik bir yaklaşımın ortaya konulması amaçlanmaktadır. Tezde önerilen hedefler doğrultusunda takip edilen işlem adımları; sınıflandırma öncesi gerçekleştirilen işlemler, sınıflandırma sırasında gerçekleştirilen işlemler ve sınıflandırma sonrasında gerçekleştirilen işlemler olarak üç temel başlık altında ele alınabilir (Şekil 1.1).

Sınıflandırma öncesi gerçekleştirilen işlem adımları,

- Arazi çalışmaları ve ağaç türlerinin tespiti,
- Spektrometre ölçümleri ile tespit edilen ağaç türlerine ait spektral özelliklerin belirlenmesi ve ağaç türlerine özgü spektral kütüphane oluşturulması,

- Spektral kütüphane yardımıyla bitki türlerinin ayırt edilebildiği en uygun spektral dalga boyu aralıkların analizi,
- Sınıflandırma ve tematik harita üretimine esas veri seti olan 8 spektral banda sahip yüksek konumsal çözünürlüklü tek uydu olan WorldView-2 uydu görüntüsünün temini,
- Uydu görüntüsünün radyometrik ve atmosferik olarak düzeltilmesi ve atmosfer üstü yansıtım değerleri hesaplanması,
- WV-2 uydu görüntüsüne ilave olarak çeşitli vejetasyon indeksleri, temel bileşenler analizi, doku özellikleri ve ton-doygunluk-yoğunluk dönüşümü ile elde edilen bileşenleri içeren yardımcı verilerin oluşturulması,
- Spektral kütüphane ile WV-2 uydu görüntüsünün ilişkilendirilerek, kütüphane yardımıyla ağaç türlerine ilişkin örnekleme alanlarının tespit edilmesi,
- Çalışma alanı içerisindeki diğer arazi örtüsü ve kullanım sınıflarının belirlenmesi ve sınıflara ait örnekleme alanlarının arazide belirlenmesi,

şeklindedir.


Sınıflandırma işleminin gerçekleştirilmesinde hem piksel hem de obje tabanlı yaklaşım değerlendirmeye alınmıştır. Karşılaştırma ve analizlerde objektifliğin sağlanması amacıyla aynı alana denk gelen eğitim ve test alanları, aynı özellik seçimi algoritmaları ve aynı sınıflandırma algoritmaları değerlendirmeye alınmıştır. Obye tabanlı sınıflandırma işleminin gerçekleştirilmesinde takip edilen işlem adımları,

- Obye tabanlı yaklaşım için görüntü segmentasyon işleminin gerçekleştirilmesi,
- Segmentasyon sonucu oluşturulan görüntü objelerine ait özelliklerin tanımlanması,
- Sınıflandırma işleminde kullanılmak üzere eğitim ve test verisi olarak kullanılacak görüntü objelerinin belirlenmesi,
- Yüksek boyutlu veri seti içerisinde 13 farklı özellik seçimi algoritması kullanarak özellik seçimi işleminin gerçekleştirilmesi,
- En uygun özellik kombinasyonu ve optimum bant sayısını tespit etmek amacıyla özellik seçimi algoritmaların belirlediği bant sıralamaları göz önüne alınarak farklı boyutlarda eğitim ve test veri setlerinin oluşturulması,



- Oluşturulan veri setleri kullanılarak geleneksel en yakın komşuluk algoritması ve 7 farklı ileri sınıflandırma algoritmasının performanslarının analizi,

şeklinde.



Şekil 1.1: Tez kapsamında takip edilen iş akış diyagramı.

Piksel tabanlı sınıflandırma yaklaşımda sırasıyla aşağıda verilen işlem adımları takip edilmiştir.

- Obje tabanlı sınıflandırmada kullanılan eğitim ve test objeleri esas alınarak piksel tabanlı sınıflandırma için eğitim ve test veri setlerinin oluşturulması,
- Yüksek boyutlu veri seti içerisinde 13 farklı özellik seçimi algoritması kullanarak özellik seçimi işleminin gerçekleştirilmesi,
- En uygun özellik kombinasyonu ve optimum bant sayısını tespit etmek amacıyla özellik seçimi algoritmaların belirlediği bant sıralamaları göz önüne alınarak farklı boyutlarda eğitim ve test veri setlerinin oluşturulması,
- Oluşturulan veri setleri kullanılarak geleneksel en yakın komşuluk algoritması ve 7 farklı ileri sınıflandırma algoritmasının performanslarının analizi,

Performans analizleri neticesinde gerek piksel gerekse obje tabanlı yaklaşımda en yüksek sınıflandırma doğruluğunun elde edildiği en uygun özellik (bant) kombinasyonu, optimum veri seti boyutu ve sınıflandırma algoritması tespit edilmiştir. Hem piksel hem de obje tabanlı yaklaşım için elde edilen optimum sınıflandırma modelleri kullanılarak tematik haritalar üretilmiştir.

Sınıflandırma sonrasında yapılan işlemler,

- Üretilen tematik haritaların görsel olarak yorumlanması ve analizi,
- Üretilen haritaların doğruluk analizlerinin gerçekleştirilmesi amacıyla eğitim ve test veri setlerinden ayrı olarak doğrulama veri setinin üretilmesi,
- Doğrulama veri seti kullanılarak tematik harita doğruluğunun araştırılması,
- Doğrulama veri seti için hata matrislerinin hesaplanması,
- Tematik haritaların genel doğruluklarının, sınıflara ait kullanıcı ve üretici doğruluklarının analizi,
- Arazi örtüsü ve arazi kullanım sınıflarının tematik harita doğruluğunun analizi ve irdelenmesi,
- Tematik haritaların genel doğrulukları arasındaki farkın anlamlılığı McNemar's testi kullanılarak istatistiksel olarak analiz edilmesi,

şeklinde dir.

#### 1.4 Literatür Çalışması

Uzaktan algılama teknolojileri sahip olduğu önemli avantajlarla yeryüzünün görüntülenmesi ve yeryüzüne ait önemli bilgilerin elde edilmesi noktasında önemli bir kaynak durumundadır. Uzaktan algılama teknolojilerinin kullanıldığı en önemli uygulama alanlarından birisi uydu görüntüleri yardımıyla arazi örtüsü ve/veya arazi kullanımının belirlenerek tematik haritalarının üretilmesidir. Uzaktan algılama verileri ile ormancılık, tarım, jeoloji, doğal kaynak, arazi örtüsü tespiti, arazi yönetim planları için altlık oluşturulmaktadır (Liu ve diğ, 2006; Kavzoglu ve Reis, 2008; Rokade ve diğ, 2007; Hu ve diğ, 2010; Kunwar ve diğ, 2010, Royer ve diğ, 2011). Kent gelişimi, kaçak yapı tespiti, orman ve doğal yapıların uğradığı zararların tespiti, afet bilgi sistemleri, kent bilgi sistemleri vb. birçok uygulama alanında uzaktan algılanmış görüntüler bölgeye ait bir veri tabanı oluşturulmasında kullanılabilmektedir (Silvestri ve Omri, 2008; Tang ve diğ, 2009; Jha ve diğ, 2009; Du ve diğ, 2009; Zhang ve diğ, 2010).

Uzaktan algılama teknolojilerinin etkin olarak kullanıldığı çalışma alanlarından birisi de yeryüzündeki doğal nesnelerin izlenmesi, tespiti, ayırt edilmesi ve zaman içinde meydana gelen değişimlerin incelenmesini de içerisine alan uygulamalardır. Bu uygulamalar içerisinde sürdürülebilir çevre ve ekolojik denge açısından büyük önem arz eden bitki tiplerinin tespiti, bitki türlerine ilişkin çeşitliliğinin ve konumsal dağılımlarının belirlenmesi, bitki gelişiminin izlenmesi, bitki sağlığı ve hastalıklarının takibi ve bitki türlerine ait yapısal parametrelerin tespiti üzerine gerçekleştirilen çalışmalar öne çıkmaktadır. Söz konusu çalışmaların uzaktan algılanmış görüntüler yardımıyla gerçekleştirilmesinde doğal nesnelere ait spektral özelliklerin belirlenmesi ve analizi önemli bir ihtiyaçtır. Bu nedenle literatürde özellikle hiperspektral uydu görüntülerinin analizinde arazide spektrometre ölçümleri ile belirlenen spektral özelliklerin de değerlendirmeye alındığı görülmektedir. Jafari ve Lewis (2012) Güney Avustralya'daki kurak arazi bileşenlerinin Earth Observing 1 (EO-1) Hyperion hiperspektral görüntüler yardımıyla ayırt edilmesi üzerine bir çalışma yapmış ve kurak arazi bileşenlerinin spektral özelliklerinin belirlenerek gruplandırmasında ASD FielSpec spektrometre cihazından faydalanmıştır. Gao ve diğ. (2012) büyüme evresindeki mera/otlak alanlarının biyokütlesinin tespit edilmesinde ASD FielSpec spektrometre cihazı ve MODIS-NDVI görüntüleri kullanmıştır. Mukherjee ve

diğ. (2010) Hindistan’da yürütülen bir çalışmada ürün çeşitliliğinin belirlenmesi ve tematik harita üretiminde 2006 yılının Şubat ve Mart aylarında görüntülenen IRS LISS-III ve AWiFS verileri ile birlikte ürünlere ait spektral özellikleri bir arada kullanmıştır. Xu ve diğ. (2011) MODIS uydusundan elde edilen NDVI (normalleştirilmiş bitki fark indeksi) kullanarak Pekin bölgesindeki geniş yapraklı orman alanlarının büyüme mevsiminin yılın hangi zaman aralıklarında olduğunu incelemişlerdir. Li ve diğ. (2005) hiperspektral yansıma ile salatalık bitkisinin gelişim durumunun incelenmesi amacıyla ASD FieldSpec cihazı ile elde edilen spektrometre ölçülerinden faydalanmışlardır. Ren ve diğ. (2008) hiperspektral uydu görüntüsü ve ASD spektrometre kullanarak pirinç ekili alanlarda su stresi değişimini incelemişlerdir. Ding ve diğ. (2010) sera domateslerindeki klorofil miktarının tespit edilmesinde spektrometre cihazı kullanmış ve domates yaprağının klorofil içeriğinin tahmini için bir model önermiştir. Hanna ve Rethwisch (2003), AVIRIS uydusu ile tarım ürünleri için ölçülen spektrometre verilerini ilişkilendirerek, uydu görüntüsünün spektral ve radyometrik özelliklerini incelemiştir. Lee ve diğ. (2007) orta derecede kurak olan bir bölgedeki orman türlerinin spektral karakteristiklerinin belirlenmesi amacıyla laboratuvar ortamında yapılan spektral ölçmelerle birlikte EO-1 Hyperion uydu görüntüleri kullanmıştır. Çalışma sonucunda orta kıvıltesi bölgede ağaçların yapraklarına ait spektral yansımalarıyla yapraklardaki su içeriği arasındaki ilişki ortaya koyulmuştur.

Son yıllarda uzaktan algılama teknolojileri ve uydu algılayıcıları tasarımında yaşanan gelişmeler beraberinde uzaktan algılama alanında yeni araştırma konularının ortaya çıkmasına neden olmuştur. Özellikle yüksek çözünürlüğe sahip uydu görüntülerinin varlığı ile birlikte yeryüzü nesnelere ilişkin gerek konumsal gerekse spektral açıdan daha detaylı bilgiler elde edilebilmektedir. Söz konusu görüntüler başta detaylı arazi örtüsü veya kullanımının haritalanması olmak üzere benzer spektral özelliklere sahip doğal ve yapay nesnelerin birbirinden ayırt edilmesi amacıyla kullanılabilmektedir. Yeni nesil uzaktan algılama teknolojilerinin yoğun olarak kullanıldığı çalışma alanlarının en önemlisi yapılaşmış bölgelerdeki benzer spektral özelliklere sahip yapay nesnelerin ayırt edilmesidir. Son yıllarda şehir alanlarının haritalanması, arazi kullanımındaki değişikliklerin izlenmesi, su geçirimsiz yüzeylerin belirlenmesi, otomatik bina ve yol çıkarımı ile ilgili uygulamalarda yüksek çözünürlüklü uydu görüntülerinin temel veri seti olarak kullanıldığı görülmektedir (Patino ve Duque,

2013; Xu, 2013; Huang ve diğ, 2014; Zhang ve diğ, 2014). Literatürde ekolojik envanter ve sürdürülebilir çevre açısından büyük öneme sahip meşcere tiplerinin ve orman ağaç türlerinin belirlenmesi, orman hastalıklarının tespiti ve biyokütle hesaplamalarında yüksek çözünürlüğe sahip uydu görüntülerinin etkin bir şekilde kullanıldığı görülmektedir (Ozdemir, 2008; Delponte ve diğ, 2012; Fernandes ve diğ, 2013; Garrity ve diğ, 2013; Hirata ve diğ, 2014).

Yüksek çözünürlüklü uydu görüntüleri kullanıcılara yeryüzü ile ilgili detaylı bilgiler sağlamasına karşın, görüntüdeki yoğun piksel sayısı, komşu pikseller arasındaki spektral benzerlik ve gölge alanlarındaki artış nesnelerin birbirinden ayırt edilmesi ve sınıflandırılması noktasında önemli problemler olarak ortaya çıkmaktadır (Zhou ve diğ, 2009; Lu ve diğ, 2011; Wieland ve Pittore, 2014). Literatürde farklı boyutta, şekilde ve dağılımda birçok yüzey özelliğini içeren yüksek çözünürlük görüntülerinin işlenmesi ve analizinde geleneksel sınıflandırma yaklaşımlarının yetersiz kaldığı ve problem çözümüne katkı sağlayacak yeni ve gelişmiş yaklaşımlara ihtiyaç duyulduğu açık bir şekilde ifade edilmiştir. Tehrany ve diğ. (2014), geleneksel piksel tabanlı sınıflandırma yaklaşımında sadece piksellere ilişkin spektral bilgilerin değerlendirmeye alınarak, konumsal, dokusal ve topolojik ilişkilerin göz ardı edilmesini yaklaşımın olumsuz yönü olarak nitelendirmiştir. Myint ve diğ. (2011), yüksek çözünürlüklü görüntülerin sınıflandırılmasında klasik sınıflandırma yaklaşımı kullanımıyla kompleks yapıdaki arazi örtüsü/kullanım sınıfların ayırt edilmesi noktasında önemli sıkıntılar yaşandığını ve bunun temel nedeninin görüntü üzerindeki piksellerin konumsal, ilişkisel ve dokusal farklılıklarının ihmal edilerek sadece spektral bilgilerin değerlendirmeye alınması olduğunu ifade etmiştir. Lu ve diğ. (2010) yüksek çözünürlüklü Quickbird uydu görüntüsü yardımıyla şehir alanına ait arazi örtüsü ve kullanımının haritalanması problemini ele almıştır. Quickbird görüntüsünün sahip olduğu yüksek konumsal çözünürlük nedeniyle aynı arazi örtüsü sınıfı içerisinde yüksek seviyede spektral değişkenlik olduğunu ve uydu görüntüsünün düşük spektral çözünürlüğünün yüksek oranda spektral karışıklığa neden olduğunu belirtmiştir. Bu durumun özellikle geleneksel piksel tabanlı sınıflandırma algoritmalarının performansını olumsuz olarak etkilediği ve sınıflandırma doğruluğunun azalmasında önemli bir etken olduğu vurgulamıştır. Problemin çözümüne yönelik olarak doku özelliklerinin, obje tabanlı sınıflandırma

yaklaşımının ve etkili bir sınıflandırma algoritmasını içeren bir sınıflandırma modeli kullanımını önermiştir.

Nesneler arasındaki spektral ayrımın daha kolay gerçekleştirilmesi ve sınıflandırma doğruluğunun artırılması amacıyla uydu görüntüleri ile birlikte yardımcı verilerin kullanılması söz konusudur (Çölkesen ve Yomralıoğlu, 2014). Literatürde uydu görüntülerinin spektral bantları yardımıyla üretilen vejetasyon indeksleri, temel bileşenler ve doku özellikleri en sık kullanılan yardımcı veri setleri arasında olduğu görülmektedir. Örneğin, Franklin ve diğ. (2000) yüksek çözünürlüklü görüntülerinin doku özellikleriyle entegrasyonu sonucunda sınıflandırma doğruluğunun önemli derecede arttığını ifade etmişlerdir. Lu ve diğ. (2010) doku özelliklerinin sadece aynı arazi örtüsü sınıfları içerisindeki spektral değişimleri azaltmakla kalmayıp, farklı sınıflar arasındaki ayırt edilebilirliği arttırdığını ifade etmiştir. Kayitakire ve diğ. (2006) IKONOS-2 görüntüsü yardımıyla orman yapısal parametrelerinin belirlenmesinde uydu görüntüsü üzerinden gri-düzey-eş oluşum matrisini yardımıyla hesaplanan doku özelliklerinin iğne yapraklı ağaç türlerine ait değişkenlerin tahmininde son derece faydalı olduğunu ifade etmiştir. Doku özelliklerinden korelasyonun ağacın yaşı ve çevresi hakkında önemli veriler sağladığını, bununla birlikte kontrast su muhtevası ve taban alanı ile ilgili önemli bilgiler sağladığı sonucuna ulaşmıştır. Ghosh ve Joshi. (2014) Worldview-2 uydu görüntüsü yardımıyla Bamboo ağaçlarının tespit edilmesinde yardımcı veri olarak gri düzey eş oluşum matrisinden hesaplanan doku özelliklerini ve ilk üç temel bileşeni kullanmıştır. Löw ve diğ. (2013) tarımsal ürünlere ait tematik harita üretiminde Rapideye uydu görüntüsünün mevcut multispektral bantlarına ilave olarak vejetasyon indeksleri, doku özellikleri, temel bileşenler ve semi-variogramlardan oluşan 71 yardımcı veri setini sınıflandırma işleminde değerlendirmeye almıştır. Shamsoddini ve diğ. (2013) çam ağacına ait yapısal parametrelerin belirlenmesinde WV-2 uydu görüntüsünü temel veri seti olarak dikkate alırken, uydu görüntüsünün spektral bantlarına ilave çeşitli bant oranlamalarını, temel bileşenleri, gri-düzey eş oluşum matrisinden hesaplanan doku özelliklerini ve 26 farklı vejetasyon indeksini yardımcı veri seti olarak kullanmıştır.

Literatürde yüksek çözünürlüklü uydu görüntüleri arasında sahip olduğu yüksek spektral ve konumsal çözünürlük nedeniyle WorldView-2 (WV-2) uydu görüntüsünün özellikle benzer spektral özelliklere sahip doğal nesnelerin ayırt

edilmesi, haritalanması, izlenmesi ve yapısal karakteristiklerinin tespit edilmesi gibi ekolojik açısından son derece önemli problemlerin çözümünde kullanımının araştırılmasına yönelik son yıllarda yoğun çalışmaların gerçekleştirildiği görülmektedir.

Aguilar ve diğ. (2013), kentsel alanlara ait arazi örtüsü ve kullanımın haritalanması probleminin çözümünde GeoEye-1 ve WV-2 görüntülerinin kullanımını incelemiştir. Çalışmada obje tabanlı yaklaşım kullanılmış ve segmentasyon sonucu üretilen görüntü objeleri için temel spektral özellikler, bant oranları, doku özellikleri, objelere ait çeşitli şekil ve geometrik özellikler yanında LIDAR görüntüsünden elde edilen sayısal yüzey modeli kullanılmıştır.

Heuman (2011) düşük konumsal çözünürlüklü uydu görüntüleri üzerinden ve/veya canlı vejetasyondan kaynaklı spektral karmaşıklık nedeniyle geleneksel uzaktan algılama yöntemleri ile Mangrove ağaçlarına ait yüksek doğruluklu tematik harita üretiminin beklenen doğrulukta olmadığını vurgulamıştır. Bu problemin çözümüne yönelik olarak yüksek konumsal ve spektral özelliğe sahip uydu görüntüsü olarak WV-2 uydu görüntüsü kullanılmıştır.

Ozdemir ve Karnieli (2011) orman yapısal parametrelerinin belirlenmesinde WV-2 uydu görüntüsünü temel veri seti olarak ele almışlardır. Uydu görüntüsünden elde edilen doku özellikleri ile orman yapısal parametreleri (ağaç sayısı, dip kaplama alanı, gövde hacmi, ClarkEvans indeksi, Contagion indeksi gibi) arasındaki ilişkiyi korelasyon analizi ile incelemiş ve yapısal parametrelerin tahmini ve haritalanmasında doku özelliklerinin kullanılması için yeterli bir ilişki ve makul bir doğruluğun elde edildiğini belirtmişlerdir.

Pu ve Landry (2012) şehir alanı içerisindeki 7 farklı ağaç türünün ayırt edilmesinde WorldView-2 ve IKONOS görüntülerinden yararlanmıştır. Çalışma sonucunda WV-2 uydu görüntüsünün sahip olduğu 8 spektral bandın ağaç türlerinin tespitinde önemli bir rol aldığı vurgulanmıştır.

Peerbhay ve diğ. (2014) 6 farklı ağaç türünün sınıflandırılmasında temel veri seti olarak WV-2 uydu görüntüsünü kullanarak ağaç türlerinin %63-%100 doğruluklarında sınıflandırıldığını ifade etmiştir. Elde edilen sonuçlar WV-2'nin sahip olduğu spektral bantların ağaç türlerinin tespit edilmesinde, ağaç türlerine

ilişkin dağılımların belirlenmesinde ve bitki sağlığının izlenmesi noktasında önemli bir veri kaynağı olduğu destekler niteliktedir.

Eckert (2012) WorldView-2 uydu görüntüsünden elde edilen doku özellikleri kullanarak orman biyokütlesin ve karbon içeriğinin belirlenmesi üzerine bir çalışma yapmıştır. Spektral özelliklerden ziyade doku özelliklerinin karbon ve biyokütle ile daha fazla korelasyona sahip olduğunu ifade etmiştir. Çalışmada WV-2 uydu görüntüsü ile birlikte, gri-düzey eş oluşum matrisinden elde edilen doku özelliklerini, WV-2 görüntüsünün bantları yardımıyla hesaplanan NDVI, ARVI, EVI, IPVI, OSAVI indekslerini ve temel bileşenler analizi ile hesaplanan bileşenleri değerlendirmeye almıştır.

Immitzer ve diğ. (2012) Avusturya ormanlarındaki 10 ağaç türünün haritalanmasında temel uydu görüntüsü olarak WV-2 kullanmıştır. Sınıflandırma işleminin gerçekleştirilmesinde hem piksel hem de obje tabanlı yaklaşım ve temel sınıflandırıcı olarak rastgele orman algoritmasının performansını analiz etmiş ve obje tabanlı sınıflandırma ile %82 genel doğruluğa ulaşırken, piksel tabanlı sınıflandırma ile %72 doğruluk elde etmiştir.

Asmaryan ve diğ. (2013) şehir parkı içerisindeki ve park çevresindeki bulunan yollar üzerinde bulunan yalancı akasya ve dış budak ağaçlarının spektral özelliklerindeki değişimlerin incelenmesinde, biyokimyasal analizler, arazide ASD spektrometre cihazıyla gerçekleştirilen spektral ölçümler ve WV-2 uydu görüntüsünü kullanmışlardır. Çalışma sonucunda yol üzerinde bulunan ağaç türlerinin spektral yansıma değerlerinin park içerisindeki ağaç türlerine göre daha yüksek olduğu, ağaç türlerine ait söz konusu spektral değişimlerin WV-2 görüntüsünün kırmızı-kenar bandı ile tespit edilebildiğini ifade etmişlerdir.

Cho ve diğ. (2012), geniş ovalar içerisindeki ağaç türlerinin ayırt edilmesinde WV-2 görüntüsünün spektral özelliklerinin kullanılabilirliğini hiperspektral ve Quickbird görüntüleri ile karşılaştırmışlardır. Elde edilen sonuçlar değerlendirmeye alınan ağaç türlerinin tespit edilmesinde WV-2 uydu görüntüsünün spektral bantlarının kullanımı ile hiperspektral ve Quickbird görüntüsüne göre daha doğru sonuçlara ulaşıldığını göstermektedir.

Collin ve diğ. (2013), mercan resifleri ve çeşitli deniz bitkilerini de içerisine alan 19 farklı arazi örtüsü ve kullanımın sınıflarına ait tematik harita üretiminde WV-2 uydu



görüntüsünü kullanmıştır. Çalışma sonuçları, WV-2 uydu görüntüsünün standart bantlarının (kırmızı, yeşil, mavi ve yakın kızılötesi-1) destek vektör makineleri ile sınıflandırılması ile bitki türleri arasındaki ayrımın başarılı bir şekilde gerçekleştirildiğini göstermektedir. Bununla birlikte WV-2 görüntüsünün yeni nesil spektral bantlarının (kıyı, sarı, kırmızı-kenar ve yakın kızılötesi-2) sınıflandırma doğruluğunu anlamlı şekilde arttırdığı ifade edilmiştir.

Deng ve diğ. (2014), 11 farklı ağaç türünün sınıflandırılması ve ağaç tepelerinin belirlenmesinde WV-2 uydu görüntüsü ve görüntü yardımıyla hesaplanan NDVI değerlerinden yararlanmıştır. WV-2 görüntüsünün yeni spektral bantlarının (kıyı, sarı, kırmızı-kenar ve yakın kızılötesi-2) ağaç türlerinin sınıflandırılmasında pozitif etkiye sahip olduğu ifade edilmiştir. Sınıflandırma işleminin gerçekleştirilmesinde piksel tabanlı yaklaşım yerine taç-tabanlı yaklaşım önerilmiştir.

Fernandes ve diğ. (2014) nehir kıyısındaki kamış ağaçlarının sınıflandırması probleminin çözümünde yüksek çözünürlüklü hava fotoğrafı ve WorldView-2 uydu görüntüsü kullanımını karşılaştırmalı olarak analiz etmiştir. Sınıflandırma işleminin gerçekleştirilmesinde obje tabanlı yaklaşım kullanmış ve segmentasyon sonucu oluşan görüntü objelerine ait geometrik, spektral ve doku özelliklerini tanımlamıştır. Çok bantlı veri seti içerisinde en uygun özelliklerin belirlenmesinde CART ve torbalama algoritmalarından yararlanmıştır. Elde edilen sonuçlar WV-2 uydu görüntüsünün sahip olduğu yüksek spektral çözünürlüğün kamış ağaçlarının tespitinde hava fotoğraflarına göre daha doğru sonuçlar vermesinde etkili olduğu vurgulanmıştır. Çalışma sonucunda WV-2'nin kızılötesi bantları, kırmızı-kenar bandı ve sarı bandının söz konusu ağaç tiplerinin ayırt edilmesinde önemli spektral bilgiler içerdiği ifade edilmiştir. Kamış ağaçlarının kapallılığının tespitinde spektral özelliklerin geometrik özelliklerle birlikte kullanımının sonucu olumlu etkilediği belirtilmiştir.

Garrity ve diğ. (2013) ağaç ölümünün araştırılmasında WorldView-2 ve Quickbird görüntülerini kullanmıştır. Çalışma sonuçları yüksek çözünürlüklü WV-2 uydu görüntüsünün çeşitli vejetasyon indeksleri ile beraber kullanımıyla canlı ve ölü ağaç türlerinin ayırt edilmesi noktasında yüksek doğruluklu sonuçlar elde edildiğini göstermektedir.

Ghosh ve Joshi (2014) bamboo ağaçlarının sınıflandırmasında yüksek çözünürlüklü WV-2 uydu görüntüsü ile birlikte doku özellikleri ve temel bileşenler analizi ile hesaplanan ilk üç bileşeni kullanmıştır. Uydu görüntüsü ve yardımcı verilerden oluşan yüksek boyutlu veri seti içerisinde özyinelemeli özellik eleme esasına dayalı destek vektör makineleri algoritması kullanarak özellik seçimi gerçekleştirmiştir. Sınıflandırma işleminde hem piksel tabanlı hem de obje tabanlı yaklaşım değerlendirmeye alınmış, destek vektör makineleri ve rastgele orman algoritmaları temel sınıflandırıcı olarak kullanılmıştır. Çalışma sonucunda özellik seçimi sonucunda belirlenen en uygun bantlar ile Bamboo ağaçlarının piksel tabanlı yaklaşımla %82, obje tabanlı yaklaşımla %94 genel doğrulukla sınıflandırıldığı ifade edilmiştir.

Jakubowski ve diğ. (2013) 6 farklı ağaç türünün ayırt edilmesinde WV-2 uydu görüntüsü ve LIDAR verisini bir arada değerlendirmiştir. Çalışma sonucunda özellikle ağaç türlerinin ayırt edilmesi noktasında WV-2 uydu görüntüsünün faydalı spektral ve konumsal bilgi sağladığı vurgulanmıştır.

Kamal ve diğ. (2014) mangrove ağaçlarının yapısal özelliklerinin tespit edilmesinde minimum piksel boyutunun tahminine yönelik gerçekleştirdiği çalışmada WV-2 görüntüsü kullanılmıştır. WV-2 uydu görüntüsünün multispektral bantları öncelikli olarak pankromatik görüntü kullanılarak görüntü kaynaştırma işlemi gerçekleştirilmiş ve 0,5 konumsal çözünürlüklü multispektral görüntü elde edilmiştir. Çalışma amacına uygun olarak söz konusu görüntü 5 farklı konumsal çözünürlükte (1m, 2m, 4m, 8m ve 10m ) yeniden örneklenerek mangrove ağaçlarının ayırt edilebildiği minimum piksel boyutu belirlenmeye çalışılmıştır.

Li ve diğ. (2014a) narenciye ağaçlarındaki yeşillenme hastalığının tespitinde 128 bantlı AISA EAGLE hiperspektral görüntüsü ile WV-2 uydu görüntüsünden faydalanmıştır. Çalışma sonucunda WV-2 görüntüsünün mavi, yeşil, sarı, kırmızı, kırmızı kenar ve yakın kızılötesi-1 bantlarında hastalıklı ve sağlıklı narenciye ağaçlarına ait spektral özelliklerin ayırt edilebilir olduğu ifade edilmiştir.

Strasser ve diğ. (2014) nehir kıyısındaki orman türlerinin haritalanmasından farklı tarihlerde algılanan WV-2 ve SPOT-5 uydu görüntülerinden yararlanmıştır. Sınıflandırma işleminin gerçekleştirilmesinde obje tabanlı yaklaşım kullanılmış ve segmente edilen görüntü objelerine ilişkin ortalama, standart sapma gibi spektral

istatistikleri, gri-düzey eş oluşum matrislerinden hesaplanan doku özelliklerini, objelere ilişkin çeşitli geometrik özellikleri ve farklı vejetasyon indekslerini değerlendirmeye almıştır.

Van Beek ve diğ. (2013) armut ağaçlarından oluşan meyve bahçelerindeki ağaçların yapısındaki su muhtevasının belirlenmesinde WV-2 uydu görüntüsünün kullanımını analiz etmiştir. Bu amaç doğrultusunda arazide ASD Fieldspec3 spektrometre cihazı ile belirlenen spektral özellikler analiz edilerek en uygun dalga boyu aralıkları tespit edilmiştir. Analiz sonucunda WV-2 görüntüsünün kırmızı-kenar bandının özellikle bitki su stresinin tespiti açısından önemli olduğu ifade edilmiştir. Bununla birlikte kırmızı-kenar ve yakın kızılötesi-1 bantları yardımıyla hesaplanan kırmızı-kenar normalleştirilmiş fark bitki indeksinin ağaçtaki su muhtevası ile yüksek korelasyona sahip olduğu belirtilmiştir.

Waser ve diğ. (2014) 7 farklı ağaç türünün sınıflandırılmasında ve dış budak ölümünün ağaç türlerini ne düzeyde etkilediğinin tespit edilmesinde temel veri seti olarak WV-2 uydu görüntüsü kullanmıştır. Uydu görüntüsünün yanında WV-2'nin spektral bantlarını kullanarak hesaplanan 19 farklı vejetasyon indeksi de değerlendirmeye alınmıştır. Sınıflandırma işleminin gerçekleştirilmesinde obje tabanlı sınıflandırma yaklaşımı kullanılmıştır. Çalışma sonucunda ağaç türlerinin ayırt edilmesinde WV-2 bantları ve söz konusu bantlarından üretilen vejetasyon indekslerinin etkili bir alternatif olduğu ifade edilmiştir.

Wieland ve Pittore (2014) Bayes algoritması, en yakın komşuluk, rastgele orman ve destek vektör makinelerinin sınıflandırma performanslarının karşılaştırılmasında orta çözünürlüklü Landsat ETM, TM ve MSS görüntüleri, yüksek çözünürlüklü Ikonos, Quickbird ve WorldView-2 uydu görüntülerini kullanmıştır. Sınıflandırma işleminde obje tabanlı yaklaşım kullanılmış ve objelere ilişkin temel spektral özellikler, geometrik ve doku özelliklerinden oluşan toplam 72 farklı özellik tanımlanmıştır. Çalışma sonucunda tüm veri setleri için DVM ve RO algoritmalarının diğerlerinden daha üstün performans sergilediği ifade edilmiştir.


Xian ve diğ. (2013) maki alanların ekosistem bileşenlerinin tespitinde WV-2 uydu görüntüsü ve büyük alanlarda dağılımlarının haritalanmasında ise Landsat TM görüntüsü kullanmıştır. Çalışma sonuçları WV-2 görüntülerinin farklı maki türlerine ilişkin özelliklerin belirlenmesinde başarıyla kullanılabileceğini, WV-2 uydu görüntüsü ile üretilen ekosistem bileşenlerinin Landsat TM ölçeğinde sınıflandırma işleminin gerçekleştirilmesinde etkili bir eğitim veri seti olabileceğini ifade etmiştir.



## 2. UZAKTAN ALGILAMADA TEMEL TANIM VE KAVRAMLAR


### 2.1 Enerji Kaynağı ve Elektromanyetik Enerji

Uzaktan algılama algılayıcıları yardımıyla yeryüzü objelerinin tanımlanmasında objelerden yayılan veya yansıyan enerji miktarının ölçülmesi esastır. Bu bağlamda güneş en önemli enerji kaynağı durumundadır. Işık bir enerjidir ve güneşten gelen elektromanyetik dalgalar halinde yeryüzüne ulaşır. Enerjinin ışıma yolu ile taşınması elektromanyetik radyasyon olarak tanımlanmaktadır. Görünür ışık, radyo dalgaları, termal, ultraviyole ve X-ray ışınları elektromanyetik radyasyonun en çok bilinen formlarıdır. Tüm bu enerji formlarının yayılımı temel dalga teorisi ile açıklanmaktadır (Lillesand ve diğ, 2007). Radyasyon genel anlamda enerjinin uzayda dalgalar ya da tanecikler (fotonlar) halinde yayılmasıdır. Şekil 2.1’den de görüleceği üzere elektromanyetik bir dalga hem birbirlerine hem de yayılma doğrultusuna dik olan elektrik alan ve manyetik alanlardan oluşmakta ve dalga teorisine göre ışık hızında ( $c = 3 \times 10^8 \text{ m/sn}$ ) harmonik sinüzoidal dalgalar şeklinde seyahat etmektedir. Elektromanyetik enerjinin dalga karakteristiği dalga boyu ( $\lambda$ ) ve frekans ( $\nu$ ) ile tanımlanır. Bir elektromanyetik dalga tepesinden diğerine olan uzaklık dalga boyu, birim zamanda sabit bir noktadan geçen dalga sayısı veya saniyedeki titreşim sayısı frekans olarak ifade edilmektedir.



Şekil 2.1 : Elektromanyetik dalgalar.

Uzaktan algılamada elektromanyetik dalgalar elektromanyetik spektrum içerisindeki dalga boyu konumlarına göre kategorize edilirler. Elektromanyetik spektrum (EMS),  $3 \times 10^8$  m/sn hızla hareket eden, dalga uzunluğu nanometreden kilometreye kadar uzanan sürekli enerji ortamıdır. Şekil 2.2’de elektromanyetik spektrum ve uzaktan algılamada kullanılan spektral bölgeler gösterilmektedir. Bu bölgeler içerisinde insan gözünün spektral duyarlılığı olarak bilinen  $0,4 \mu\text{m}$  ile  $0,7 \mu\text{m}$  dalga boyu aralığı görünür bölge olarak tanımlanmaktadır. Görünür bölge içerisinde mavi ( $0,4 - 0,5 \mu\text{m}$ ), yeşil ( $0,5 - 0,6 \mu\text{m}$ ) ve kırmızı ( $0,6 - 0,7 \mu\text{m}$ ) renge karşılık gelen dalga boyları bulunmaktadır. Ultraviyole (morötesi) enerji spektrumun görünür bölgesinde mavi banda komşu bölgede konumlanmıştır. Görünür bölgenin bitiminde kırmızı dalga boyuna bitişik olarak kızılötesi dalga boyları sırasıyla yakın kızılötesi ( $0,7 - 1,3 \mu\text{m}$ ), orta kızılötesi ( $1,3 - 3 \mu\text{m}$ ) ve termal kızılötesi ( $3 - 14 \mu\text{m}$ ) bulunmaktadır. Bunlar dışında kalan daha uzun dalga boyları ( $1 \text{ mm} - 1 \text{ m}$ ) elektromanyetik spektrumun mikrodalga bölgesini oluşturmaktadır.



**Şekil 2.2 : Elektromanyetik spektrum.**

Elektromanyetik radyasyonun birçok karakteristik özelliği dalga teorisi ile açıklansa da enerji ile nesne arasındaki ilişkinin tanımlanmasında kuantum teorisi kullanılır. Bu teoride elektromanyetik radyasyonun foton veya kuantum olarak adlandırılan birçok elemandan oluştuğu kabul edilir. Bu durumda bir kuantumun dalga boyu ile taşıdığı enerji (2.1) yardımıyla hesaplanır.

$$E = h \frac{c}{\lambda} \quad (2.1)$$

(2.1)'de  $h$  Planck sabitini,  $c$  ışık hızını ve  $\lambda$  dalga boyunu göstermektedir. Eşitlikten hareketle enerjinin frekansla doğru ve dalga boyuyla ters orantılı olduğu ifade edilebilir. Diğer bir ifadeyle dalga boyu arttıkça taşınan enerji miktarı azalmaktadır (Lillesand ve diğ, 2007). Uzaktan algılama uygulamaları açısından ele alındığında yeryüzünün algılanması için mikrodalga gibi uzun dalga boyları ile algılanabilecek enerji miktarı kızılötesi dalga boyundan daha az olacaktır.

## 2.2 Enerji-Atmosfer Etkileşimi ve Atmosferik Pencereleler

Kaynağı ne olursa olsun uzaktan algılama algılayıcıları tarafından kaydedilen tüm radyasyonların (enerjinin) atmosfer ile etkileşimi söz konusudur. Bu enerjinin atmosferi oluşturan bileşenlerle etkileşimi sonucunda enerji bir takım değişikliklere uğrar. Atmosferin radyasyon üzerindeki etkisi atmosfer içerisinde alınan yola, algılanan enerjinin miktarına, dalga boyuna ve atmosferik koşullara bağlı olarak değişkenlik gösterebilmektedir. Atmosfer genel olarak uzaktan algılama verilerini saçılma ve soğurulma olmak üzere iki şekilde etkileyebilir. Atmosferik saçılım atmosferdeki partiküller (parçacıklar) nedeniyle radyasyonun öngörülemeyen bir şekilde saçılmasıdır. Bu partiküller atmosferi oluşturan gaz molekülleri, toz tanecikleri ve su damlacıklarıdır. Saçılım, teorik olarak saçılan ışının dalga boyu ile saçılıma neden olan taneciklerin büyüklüğü arasındaki bağıntıya bağlı olarak üç farklı kategoriye ayrılabilir. Bunlar Rayleigh, Mie ve Seçici olmayan saçılımlardır (Lillesand ve diğ, 2007).

Rayleigh Saçılımı, etkileşime geçen radyasyonun dalga boyunun saçılıma neden olan taneciklerden çok daha büyük olması halinde oluşur. Rayleigh saçılımının etkisi dalga boyunun dördüncü kuvveti ile ters orantılıdır. Bu nedenle küçük dalga boyuna sahip radyasyonlar büyük dalga boyuna sahip radyasyonlara göre bu saçılımdan daha fazla etkilenmektedirler. Güneşten gelen radyasyon atmosfer ile etkileşime girdiğinde görünür bölgedeki en düşük dalga boyuna sahip mavi dalga boyu diğerlerine göre daha fazla saçılıma uğradığından Rayleigh saçılımının bir sonucu olarak gökyüzü mavi gözükmetedir. Rayleigh saçılımı nedeniyle uzaktan algılanmış

görüntüde üzerinde pus meydana gelir. Görsel açıdan ele alındığında pus nedeniyle görüntünün canlılığı veya kontrastı azalmaktadır.

Mie saçılımı, ışığın dalga boyunun atmosferdeki taneciklerle yaklaşık eşit büyüklüklerde olması durumunda ortaya çıkan bir atmosferik saçılımdır. Genel olarak atmosferdeki su buharı ve toz tanecikleri nedeniyle oluşmaktadır. Rayleigh saçılımı ile karşılaştırıldığında daha uzun dalga boylarını etkileyebilmektedir. Seçici olmayan saçılım ise, taneciklerin algılanan radyasyonun dalga boyundan çok daha büyük olması halinde oluşur. Atmosferdeki su damlacıkları bu saçılımın ortaya çıkmasında etkili olan partiküllerdendir. Bu saçılım nedeniyle görünür bölgede mavi, yeşil ve kırmızı dalga boyu aralıklarında eşit miktarda saçılım olur.


Atmosferik saçılımın tersine atmosferik soğurma neticesinde atmosferin bileşenleri nedeniyle enerjinin çok büyük bir kısmı kaybolur. Bu durum belirli bir dalga boyu aralığındaki enerjinin soğrulması anlamına gelmektedir. Güneşten gelen radyasyonun atmosfer içinde soğrulmasında genel olarak su buharı, karbon dioksit ve ozon gazlarının etkisi vardır. Atmosferde söz konusu gazlar belirli dalga boyu aralıklarında elektromanyetik enerjiyi soğrulmakta, bazı bölümlerin de ise enerji geçişine izin vermektedir. Atmosferin enerji geçişine izin verdiği dalga boyu aralıkları atmosferik pencereler olarak adlandırılmaktadır. Elektromanyetik spektrumda atmosferik pencerelerin bulunduğu dalga boyu bölgelerinde atmosferin içerisinde bulunan bileşikler güneşten gelen elektromanyetik enerjiyi; soğurma, yansıtma ve saçılma nedeniyle fazlaca etkilemezler. Bu nedenle, atmosfere gelen enerji pencerelerin bulunduğu yerlerden geçerek yeryüzüne ulaşabilirken, pencerelerin bulunmadığı dalga boyu aralıklarında atmosferden hemen hemen hiç geçememekte, dolayısıyla yer yüzeyine ulaşamamaktadır. Başlıca atmosferik pencereler, mor ötesi, görünür bölge, termal bölge, mikrodalga ve radar bölgelerinde bulunmaktadır.

### **2.3 Enerji-Nesne Etkileşimi ve Nesnelerin Spektral İmzası**

Elektromanyetik enerji yeryüzündeki bir nesneye veya yüzeye ulaştığında üç temel enerji-nesne etkileşimi söz konusudur. Bir cisme veya yüzeye kaynaktan (güneş) gelen enerji nesne tarafından yutulur (soğurulur), yansıtılır ve/veya geçirilir (Şekil 2.3). Yeryüzüne gelen enerji ( $I$ ) dünya yüzeyine çarptığında yeryüzündeki nesneler tarafından soğrulabilir ( $A$ ), geçirilebilir ( $T$ ) ve yansıtılabilir ( $R$ ). Gelen enerji yer



yüzeyinde söz konusu üç tip etkiden biri veya daha fazlası ile karşılaşmaktadır. Bunlardan her birinin etkileme oranı; enerjinin dalga uzunluğuna, yüzeydeki materyale ve şartlara bağlı olarak değişmektedir. Enerji ve nesne arasındaki bu ilişki uzaktan algılamanın temelini oluşturmaktadır.



**Şekil 2.3 : Enerji ve nesne etkileşimi.**

Enerji korunumu prensibi göz önüne alınırsa, söz konusu nesne-enerji etkileşimleri arasındaki ilişki (2.2)'de verilen enerji-denge denklemi ile ifade edilebilir.

$$E_I(\lambda) = E_R(\lambda) + E_A(\lambda) + E_T(\lambda) \quad (2.2)$$

(2.2)'de  $E_I(\lambda)$  yeryüzüne gelen toplam radyasyon(enerji) miktarını,  $E_R(\lambda)$  nesneden yansıyan enerji miktarını,  $E_A(\lambda)$  nesne tarafından soğrulan (yutulan) enerji miktarını ve  $E_T(\lambda)$  nesne tarafından geçirilen enerji miktarını ifade etmektedir. Bu etkileşimle ilgili iki önemli husus vardır. Bunlardan ilki yutulan, yansıtılan veya geçirilen enerji miktarı yapısal özelliği ve ortam koşullarına göre yeryüzündeki her nesne türü için değişkenlik gösterir. Söz konusu farklılıklar nesnelerin görüntü üzerinde ayırt edilmesine imkan sağlamaktadır. Diğer bir ifadeyle, yeryüzü üzerindeki nesnelerin uzaktan algılama yöntemiyle ayırt edilebilmelerinin en önemli nedeni; nesnelerin enerji ile ilişkilerinin farklı olmasıdır. Uzaktan algılamada buna nesnelerin imzası veya özel davranışı denir. Enerji nesne


etkileşiminde diğer önemli bir husus yeryüzündeki bir nesneye ait yutulan, yansıyan ve/veya geçirilen enerji miktarının farklı dalga boyları için değişiklik göstermesidir. Bu nedenle iki yeryüzü nesnesi belirli bir spektral dalga boyu aralığında benzer özellikler sergilerken, bir başka dalga boyu aralığında birbirinden çok farklı özelliklere sahip olabilmektedir.

Uzaktan algılama sistemleri, seçilen dalga boyu aralıklarında yer yüzeyindeki nesnelerden yansıyan ve yayılan enerji miktarlarındaki değişimleri kayıt etmektedir. Veriler, fotoğraflık algılayıcılarla doğrudan doğruya fotoğraflık film olarak kaydedilebileceği gibi; tarayıcı sistemlerle yansıyan veya yayılan enerji manyetik bir banda sayısal olarak kaydedilebilir. Daha sonra elde edilen bu veriler yeryüzü üzerindeki objelerin yorumlanması ve analizi için kullanılmaktadır. Birçok uzaktan algılama algılayıcısı tarafından yansıyan enerjinin yoğun olduğu dalga boyu aralıklarında algılama yapıldığından, yeryüzü üzerindeki nesnelerin yansım özelliklerinin bilinmesi son derece önemlidir. Nesnelerin yansıtma karakteristikleri, nesne üzerine gelen toplam enerji miktarı kullanılarak ölçülebilir. Buradan hareketle, belirli bir dalga boyundan yansıyan enerji miktarının; nesne tarafından soğrulan ve iletilen enerjinin toplamından bu dalga boyunda nesne üzerine gelen enerjiden çıkarılmasına eşit olduğu ifade edilebilir. Yansım miktarı, nesne tarafından yansıtılan enerji miktarının o nesne üzerine gelen toplam enerji miktarına oranı şeklinde ifade edilir. Dalga boyu ile ilişkili olan bu yansım spektral yansım ( $\rho_\lambda$ ) olarak adlandırılır ve (2.3) yardımıyla hesaplanmaktadır.

$$\rho_\lambda = \frac{E_R(\lambda)}{E_I(\lambda)} = \frac{\lambda \text{ dalga boyu aralığında nesne tarafından yansıtılan enerji miktarı}}{\lambda \text{ dalga boyu aralığında nesne üzerine gelen toplam enerji miktarı}} \times 100 \quad (2.3)$$

Uzaktan algılanmış görüntüler üzerinden yeryüzü üzerindeki objelerin ayırt edilmesinde temel düşünce her objenin farklı spektral özelliğe sahip olmasıdır. Uzaktan algılanan verilerinin bilgisayar ortamında analiz edilebilmesi için objelerin spektral özelliklerinin bilinmesi gerekmektedir. Bu nedenle çeşitli bitki örtülerinin, toprağın, suyun ve ilgilenilen diğer yer yüzeyi özelliklerinin spektral özelliklerinin bilinmesi, uzaktan algılanan verilerin uygun bir şekilde analizi ve yorumlanması açısından son derece önemlidir.

Bitki örtüsünün spektral yansıtımı dalga boyuna göre değişim göstermektedir. Yapraktaki pigmentler, yaprağın fizyolojik yapısı ve yapraktaki su miktarı bitki örtüsü için yansımada, yutulmada ve geçirimde önemli etkiye sahiptir (Swain ve Davis, 1978; Nag ve Kudrat, 1998). Şekil 2.4’de bitki örtüsünün genel spektral özelliklerini açıklamak amacıyla Çınar (*Platanus orientalis L.*) ağacına ait spektral yansımaya eğrisi gösterilmiştir.




**Şekil 2.4 :** Çınar (*Platanus orientalis L.*) ağacına ait spektral yansımaya eğrisi.

Görünür bölge olarak bilinen 400-700nm dalga boyu aralığında yaprakta bulunan pigmentler (özellikle klorofil maddesi) spektral yansımaya özelliklerinin belirlenmesi açısından önemli bir etkindir. Şekilden de görüleceği üzere görünür bölgede mavi ve kırmızı bantlarda kuvvetli klorofil soğurması görülürken, yeşil bantta klorofil soğurması daha azdır. Elektromanyetik spektrumun yakın kızılötesi (NIR) dalga boyu aralığında yeşil yaprak gelen enerjinin çok az bir kısmını soğurup büyük bir kısmını yansıttığından, spektral yansıtım önemli derecede artmaktadır. Yeşil dalga boylarındaki bu düşük soğurma sağlıklı yaprakları yeşil olarak görmemize neden olmaktadır. Bitkilerin yapısında karoten, ksantofil ve antosyanin pigmentleri bulunmaktadır. Yeşil bir bitki yaşlandıkça yapısındaki klorofil miktarı azalır ve bitki

yapısındaki karoten ve ksantofil pigmentleri baskın hale gelir. Bu durum ağaç yapraklarının son baharda sarı renk almasının temel nedenidir. Bazı ağaç türlerinin sonbaharda açık kırmızı görünmesinin nedeni ise aynı şekilde klorofil miktarının azalması ile birlikte ağaç yapısındaki antosyanin pigmentlerinin baskın hale gelmesidir (Maktav ve Sunar, 1991). Orta kızılötesi (SWIR) bölgede yaprakta bulunan su miktarı spektral yansıma özelliklerini belirleyen önemli bir faktördür. Su soğurma bantları olarak da bilinen belirli dalga boylarında gelen enerjinin büyük bir kısmı bu bölgede soğrulmaktadır.

Toprağın spektral özellikleri incelendiğinde bitki örtüsüne göre daha az karmaşık yapı söz konusudur (Şekil 2.5). Bu nedenle toprağın yansımasını etkileyen faktörlerin belirli spektral bant aralığında etkili olduğu söylenebilir. Topraktaki nem miktarı, toprağın yapısındaki organik madde içeriği, toprağın doku özellikleri, yüzey eğriliği ve topraktaki demir oksit varlığı toprağın spektral özelliğini belirleyen temel faktörlerdendir (Lillesand ve diğ., 2007). Söz konusu faktörler karmaşık, değişken ve birbirleriyle ilişkili bir yapıya sahiptir. Örneğin topraktaki nem miktarı arttıkça yansıma miktarı azalmaktadır. Toprak nemliliği ise genel olarak toprak dokusu ile ilişkilidir. Örneğin kumlu toprak suyu genellikle iyi drene eder. Bu nedenle bünyesinde düşük nem ihtiva ederek gelen enerjinin büyük bir kısmını yansıtır. Yüzey pürüzlülüğü ve topraktaki organik madde içeriği toprak yansıtımını azaltan faktörlerdir. Topraktaki demir oksit varlığı da özellikle görünür bölgede toprak yansımalarını önemli derecede azaltan bir faktördür.



Şekil 2.5 : Toprak ve su için genelleştirilmiş spektral yansıtım grafiği.

Suyun spektral yansıma özellikleri göz önüne alındığında özellikle yakın kızılötesi ve orta kızılötesi dalga boyu aralığında diğer türlerden kolaylıkla ayırt edilebileceği görülmektedir (Şekil 2.5). Söz konusu dalga boylarında su kitleleri gelen enerjinin neredeyse tamamını soğurur ve çok az bir kısmını yansıtır. Suyun bu spektral özelliği uzaktan algılama ile suyun diğer nesnelerden kolaylıkla ayırt edilmesini sağlamaktadır. Su içerisinde bulunan organik veya organik olmayan çeşitli büyüklükteki maddeler suyun spektral özelliğinde önemli değişikliklere neden olabilen unsurlardandır. Örneğin bulanık nehir suyu ile berrak göl suyunun spektral özellikleri kızılötesi bölgede önemli farklılıklar gösterebilmektedir.

## **2.4 Uzaktan Algılamada Çözünürlük**

Uzaktan algılamada genel olarak konumsal, spektral, radyometrik ve zamansal çözünürlükler söz konusudur (Mather ve Koch, 2011). Konumsal çözünürlük algılayıcının anlık görüş açısı (IFOV) ile ilişkili olup belirli bir anda algılayıcı tarafından kaydedilen enerjiye karşılık gelen yeryüzündeki alandır. Diğer bir ifadeyle, herhangi bir anda belirli bir yükseklikten algılayıcı ile gözlenen veya kayıt edilen yeryüzü alanı olarak tanımlanabilir. Söz konusu alan görüntü üzerinde yaklaşık olarak bir piksele karşılık gelmektedir. Bu nedenle konumsal çözünürlük uzaktan algılanmış görüntüdeki piksel boyutu ile direkt olarak ilişkilidir. Konumsal çözünürlüğün artmasıyla görüntüdeki objelerin birbirinden ayırt edilebilirliği artmakta ve yorumlama açısından daha kolay bir hale gelmektedir.

Spektral çözünürlük, algılayıcının kaydedebileceği elektromanyetik spektrumun dalga aralıklarını ve sayısını ifade etmektedir. Bu çözünürlük genel olarak kullanılan bantların sayısını ve genişliğini ifade eder. Spektral çözünürlük yeryüzündeki cisimlerin ve arazi türlerinin uzaktan algılama yolu ile tanımlanabilmeleri için gerekli olan en önemli özelliktir. Spektral özellik, her cismin yansıma, yayılma, geçirgenlik ve soğurma özelliği olarak ifade edilebilir. Algılayıcılar bu spektral özelliklerdeki değişiklikleri kaydedebilecek şekilde tasarlanmıştır. Yeryüzündeki cisimlerin spektral özellikleri ile kendilerine has özellikleri arasında kuvvetli bir ilişki vardır. Her spektral bant elektromanyetik spektrumun belirli bir bölümüne duyarlıdır. Bu bölümlerde başlangıç ve bitiş dalga boyları ya da merkez frekansı ve bant genişliği biçiminde verilir. Uzaktan algılama aletlerinin spektral ayırma gücü kullanılan bant genişliği ile belirlenir.

Piksellerin yapısı, bir görüntünün yapısını tanımlarken, radyometrik özellikler bir görüntüdeki gerçek bilgiyi ifade etmektedir. Bir filmde ya da bir algılayıcı tarafından elde edilen görüntünün elektromanyetik enerji miktarına duyarlılığı, radyometrik çözünürlüğü ifade etmektedir. Yeryüzündeki her bir piksele karşılık gelen alanlardan yansıyan ışığın şiddetine göre her obje, algılayıcılar tarafından değişik derecelerde kaydedilir. Buna o alıcının radyometrik çözünürlüğü adı verilir. Kısaca radyometrik çözünürlük, objeleri tanımlamada ve ayırt etmede kullanılan toplam renk tonu sayısıdır. Derecelendirme veya tonlandırma ne kadar yüksek olursa, ayırt etme gücü de o kadar yüksek olur.

Uzaktan algılama sistemleri için zamansal çözünürlük, aynı alan için hangi sıklıkta verilerin edinildiğini ifade etmektedir. Diğer bir ifadeyle, bir uzaktan algılama uydusunun belirli bir alanı ardışık olarak algılayabileceği zaman dilimidir. Görüntülerin farklı zamanlarda, değişik zaman aralıklarıyla alınması çok zamanlı uydu görüntülerin elde edilmesine imkan sağlamaktadır.

## **2.5 Uzaktan Algılamada Görüntü Analizi ve Ön İşlemler**

Uydu platformları üzerindeki algılayıcılar tarafından kaydedilen ham haldeki uzaktan algılanmış veriler genellikle birtakım hatalar veya eksiklikler içermektedir. Bu hataların düzeltilmesi veya eksikliklerin giderilmesi uzaktan algılamada ön işlemler olarak tanımlanmaktadır. Ön işlemlerin gerçekleştirilmesinde temel amaç algılayıcı ve platformdan kaynaklanan radyometrik ve geometrik bozulmaları ortadan kaldırılmasıdır. Söz konusu işlemler uzaktan algılama verisinin belirli bir amaç için kullanılmasından önce gerçekleştirilmektedir. Radyometrik düzeltmeler, algılayıcı düzensizlikleri, istenmeyen algılar, atmosferik gürültülerin düzeltilmesi ve algılayıcı tarafından ölçülen radyasyonun doğru şekilde gösterimi için gerekli dönüşümleri içerir. Düzeltmelerin bazıları yer istasyonlarında yapılmasına rağmen, kullanıcı tarafından da düzeltme yapılmasına sıkça gerek duyulmaktadır. Bu düzeltmelerden birisi, atmosferik etkilerin giderilmesi amacıyla yapılan düzeltmelerdir. Geometrik sapmalar ise birçok faktöre bağlıdır. Bunlar arasında algılayıcı optiğinin yapısı, tarama sistemlerinin hareketi, platform hareketi, platformun yüksekliği, arazinin eğimi ve yeryüzünün küreselliği en önemli olanlarıdır.

### 2.5.1 Atmosferik düzeltmeler

Uydular üzerindeki algılayıcılar yeryüzünde görüntülenen alan ile ilgili elektromanyetik radyasyon yoğunluğunu her bir spektral bant için ayrı bir parlaklık değeri olarak kaydederler. Bu parlaklık değerlerinin genişliği algılayıcı özelliklerine ve algılayıcının radyometrik çözünürlüğüne bağlı olarak değişiklik göstermektedir. Örneğin Landsat MSS algılayıcısı ölçülen radyasyonu 0-63 aralığındaki parlaklık değerleriyle ifade ederken, TM algılayıcısı 0-255 aralığında ölçeklendirmektedir. Yeryüzündeki nesnelerden yansıyan enerji algılayıcılar tarafından parlaklık değerleri şeklinde kaydedildiğinden spektral imzaları yansıtmazlar. Bu parlaklık değerleri algılayıcıya özel olup, görüntünün çekildiği andaki uydunun bakış geometrisine, güneşin görüntü alma zamanındaki konumuna ve çekim anındaki hava koşullarına bağlıdır. Bu nedenle algılayıcı tarafından kaydedilen parlaklık değerlerinden ziyade spektral yansıma değerlerinin kullanılması birçok uygulama için büyük önem teşkil etmektedir. Parlaklık değerleri yerine spektral yansıma değerlerinin kullanılmasının iki önemli avantajı vardır (Mather ve Koch, 2011),

1. Eğer iki görüntünün karşılaştırılması söz konusu ise spektral değerlerin kullanılması daha anlamlıdır. Bu durum özellikle birden fazla görüntü ile çalışma alanının ifade edilebildiği durumlarda veya belirli bir bölgede meydana gelen zamansal değişimlerin incelenmesinde ortaya çıkabilmektedir.


2. Yeryüzünde gerçekleştirilen spektrometre ölçümleri ile direkt olarak nesnelerin spektral yansıma değerleri kaydedilmektedir. Elde edilen bu spektral değerler ile spektral kütüphaneler oluşturulabilmekte ve nesnelerin spektral imzaları karşılaştırılabilmektedir.

Atmosfer üzerindeki algılayıcıya ulaşan radyans ile yeryüzündeki nesneden yansıyan radyans arasındaki ilişki (2.4) ile ifade edilebilir.

$$L_s = H_{tot}\rho T + L_p \quad (2.4)$$

Eşitlikte  $H_{tot}$  belirli bir spektral bant aralığında gönderilen toplam radyansı,  $\rho$  hedefin reflektans değerini (yansıyan ve gelen radyans değerlerinin oranı) ve  $T$  ise atmosferin geçirgenliğini göstermektedir.  $L_p$  ise atmosferik radyans yolu olarak adlandırılmaktadır. Işın kaynağından gelen ve atmosfer tarafından zayıflatılan

Radyans atmosfer üzerinden geçerek hedefe ulaşır. Aynı şekilde hedeften yansıyan enerji tekrar atmosferden geçerek algılayıcıya ulaşır. Diğer bir ifadeyle, uydu algılayıcıları tarafından elektromanyetik radyasyon kaydedildiği anda, söz konusu radyasyon atmosferden iki kez geçmiş (güneş-hedef, hedef-algılayıcı) olur (Şekil 2.6). Hedef üzerine gelen radyansın bir kısmı yeryüzündeki materyaller tarafından soğrulur ve  $\rho$  ile ifade edilen reflektans oranı kadar yansıma yapar. Bununla birlikte hedef dışındaki nesnelerden de saçılan enerjide algılayıcının anlık görüş alanı içerisine dahil olmaktadır. Tüm bu yansımaların dışında hedef üzerine gelen ışığın bir kısmı direkt olarak atmosfer tarafından saçılarak algılayıcıya ulaşır. Bu yansıma eşitlikte  $L_p$  ile gösterilmiş ve atmosferik radyans yolu olarak adlandırılmıştır. Radyans yolu dalga boyu ile ters orantılı olup dalga boyu azaldıkça saçılma artmaktadır. Bu nedenle  $L_p$  her bir spektral dalga boyu için farklı miktarlarda sonuca etki etmektedir. Örneğin Landsat TM veya ETM+ görüntülerinde mavi bant genel olarak yeşil banda göre daha yüksek  $L_p$  değeri almaktadır (Mather ve Koch, 2011).



Şekil 2.6 : Radyasyonun atmosferle etkileşimi (Url-1).

Yeryüzü üzerindeki nesnelere ait anlamlı yansıma ölçümlerinin yapılabilmesi için görüntü üzerindeki söz konusu atmosferik etkilerin giderilmesi gerekmektedir. Uzaktan algılama alanında bu işlem atmosferik düzeltme olarak adlandırılmaktadır. Radyometrik düzeltmenin temel amacı uydu görüntülerinin algılanması sırasında



ortaya çıkan atmosferik etkileri azaltmak ve uydu görüntüsüne ait piksel parlaklık değerlerini yersel spektral yansıtma değerleri ile spektral olarak karşılaştırılabilir birime dönüştürmektir. Radyometrik düzeltme işlemi genel olarak iki aşamada gerçekleştirilir. İlk olarak piksel parlaklık değerlerini ifade eden sayısal numaralar spektral radyans (parlaklık) değerlerine dönüştürülür. Daha sonra, spektral radyans değerlerinden görüntü üzerindeki piksellere ait spektral yansıtma (reflektans) değerlerine dönüşüm işlemi gerçekleştirilir. Atmosferik düzeltme işleminin gerçekleştirilmesinde karanlık nesne çıkarımı (Dark Object Subtraction), histogram eşitleme, sabit nesne (Invariant Object), kontrast azaltma, deneysel çizgi (Empirical Line) ve ışımsal transfer (Radiative Transfer) yöntemleri en çok kullanılanlar arasındadır (Mather ve Koch, 2011).

Uydu görüntüleri ile arazide gerçekleştirilecek spektral ölçümlerinin ilişkilendirilebilmesi için ön koşul, uydu görüntüsüne atmosferik düzeltme getirilerek sayısal numaralar olarak kaydedilen yansıtma değerlerinden spektral yansıtma değerlerine geçilmesidir. Radyometrik düzeltmenin amacı her bir bant için tek bir mutlak kalibrasyon faktörü kullanılarak görüntüdeki tüm piksellerin atmosfer-üstü (top-of-atmosphere) spektral radyans değerlerinin hesaplanmasıdır. Bu geçiş sürecinde ilk işlem adımı görüntüdeki piksellerin atmosfer-üstü spektral radyans değerlerinin hesaplanmasıdır. Radyans değerlerinin hesaplanmasının ardından ikinci işlem adımı solar geometrinin belirlenmesidir. Solar geometrinin belirlenmesinde görüntünün kaydedildiği tarih ve zamandan hareketle Julian günü hesaplamaları, Dünya-Güneş uzaklığı ve solar zenit açısı hesabı gibi hesaplamalar gerçekleştirilmektedir. Üçüncü işlem adımında ise atmosfer-üstü spektral radyans değerleri ve solar geometri kullanılarak ham görüntüdeki piksellere ait sayısal numaralardan atmosfer-üstü yansıtma değerleri hesaplanmaktadır.

### **2.5.2 Geometrik düzeltmeler**

Uzaktan algılanmış görüntünün belirli bir harita projeksiyonuna dönüşümü için ölçek ve projeksiyon özelliklerinin tanımlanması işlemleri geometrik düzeltme olarak adlandırılmaktadır (Mather ve Koch, 2011). Geometrik düzeltmenin amacı, görüntüyü geometrik olarak gerçek dünyaya en yakın şekle dönüştürmektir. Geometrik sapmaların birçoğu sistematik olduğundan uygun modeller oluşturularak giderilebilir. Sistematik olmayan veya rastgele hatalar modellenemez. Geometrik

düzeltilme, bilinen bir koordinat sistemine dönüşüm yapılarak sağlanabilir. Geometrik düzeltilme işlemi ile ham haldeki uydu görüntüsü, bulunduğu resim koordinat sisteminden, görüntü üzerinde ve arazideki koordinatları bilinen uygun sayı ve konumdaki yer kontrol noktaları yardımıyla arazi koordinat sistemine dönüştürülür. Bu işleme görüntüden haritaya geçiş denir. Ham haldeki görüntünün geometrik olarak düzeltilmesinde kullanılan bir diğer yöntem görüntüden görüntüye dönüşümdür. Bu yöntemde daha önce coğrafik olarak referanslandırılmış diğer bir görüntü yardımıyla, her iki görüntüdeki ortak noktalar kullanılarak geometrik düzeltilme işlemi gerçekleştirilir.

Uydu görüntüleri geometrik olarak düzeltilip kullanıcı tarafından belirlenmiş herhangi bir koordinat sistemine bağlandıktan sonra ortaya çıkan görüntü eğiminden dolayı oluşan piksellere yeni değerlerin atanması gerekir. Diğer bir ifadeyle, geometrik olarak düzeltilmiş görüntü üzerindeki piksellere ait sayısal bilgiler geometrik dönüşüm sonucunda olması gerekenden farklı olabilirler. Bu nedenle düzeltilmiş görüntüdeki yeni piksellerin sayısal değerlerinin belirlenmesinde yeniden örnekleme adı verilen bir işlem kullanılır. Yeniden örnekleme ile geometrik dönüşüm öncesinde görüntüdeki orijinal sayısal piksel değerleri yardımıyla yeni piksel değerleri hesaplanır. En yakın komşuluk, bilineer enterpolasyon ve kübik eğri olarak bilinen üç farklı yöntem yeniden örnekleme işleminin gerçekleştirilmesinde yaygın olarak kullanılmaktadır. En yakın komşuluk yönteminde, orijinal görüntüde yeni piksel konumuna en yakın sayısal piksel değerlerinden faydalanılarak düzeltilmiş piksel değerleri hesaplanır. Bu yöntem basit bir mantığa dayanır ve orijinal değerler değişmediğinden en çok tercih edilen yöntemdir. Bilineer enterpolasyon yönteminde, orijinal görüntüde yeni piksel konumuna en yakın dört pikselin ortalama ağırlığı kullanılarak yeni piksel değerleri hesaplanır. Bu durumda orijinal piksel değerleri değişir ve yeni piksel değerleri oluşur. Kübik eğri yöntemi ile yeniden örnekleme işleminde orijinal görüntüde yeni piksel konumunu çevreleyen sekiz pikseli bir bloğun ağırlıklı ortalaması kullanılarak yeni piksel değeri hesaplanır. Bilineer enterpolasyonda olduğu gibi bu yöntemde tamamen yeni piksel değerleriyle sonuçlanır.

### 2.5.3 Görüntü kaynaştırma

Uzaktan algılamada çok bantlı uydu görüntülerinin mevcut konumsal çözünürlüğünün aynı bölgeye ait daha yüksek konumsal çözünürlüğe sahip pankromatik görüntüler yardımıyla iyileştirilmesi işlemlerine görüntü kaynaştırma adı verilmektedir. Kaynaştırma işleminin temel amacı pankromatik görüntüdeki konumsal detayın multispektral görüntüye aktarılması ve aynı zamanda multispektral görüntüdeki spektral içeriğin gerçeğine uygun olarak saklanmasıdır (Mather ve Koach, 2011). Diğer bir ifadeyle, düşük çözünürlüklü multispektral görüntünün sahip olduğu spektral değerlerin kaynaştırılmış görüntüde de korunarak görüntünün konumsal çözünürlüğünün artırılmasıdır. Kaynaştırma işlemi görüntünün görsel olarak analizini kolaylaştırmanın yanında görüntü analizi, özellik çıkarımı, modelleme ve sınıflandırma doğruluğunun iyileştirilmesine de katkı sağlamaktadır (Yang ve diğ, 2012).

Literatürde görüntü kaynaştırma işleminin gerçekleştirilmesi amacıyla birçok algoritma geliştirilmiş ve uygulamalarda kullanılmıştır (Pohl ve Van-Genderen, 1998; Du ve diğ, 2007; Amro ve diğ, 2011; Zhang ve Misra, 2012; Sarp, 2014). Bu algoritmalar arasında ton-doygunluk-yoğunluk dönüşümü (IHS), temel bileşenler analizi (PCA), Brovey dönüşümü ve Gram-Schmidt (GS) en çok kullanılanlar arasındadır. IHS dönüşümünün görüntü kaynaştırma işleminde kullanımında, ilk olarak geometrik olarak düzeltilmiş ve yeniden örneklenmiş multispektral görüntüye ileri yönlü dönüşüm işlemi uygulanır. Dönüşüm sonrası elde edilen görüntüden HSI bileşenleri çıkarılır. Söz konusu bileşenlerden yoğunluk (intensity) pankromatik görüntüyle değiştirilerek geri yönlü dönüşümle RGB renk uzayına geçiş yapılır.

Uydu görüntüsüne temel bileşenler analizi uygulanması sonucunda elde edilen ilk temel bileşen tüm multispektral bantların ağırlıklı ortalamasını göstermektedir. Temel bileşenler analizi ile gerçekleştirilen görüntü kaynaştırma işleminde, ilk temel bileşen yüksek çözünürlüklü pankromatik görüntüyle değiştirilerek ters yönde temel bileşenler analizi uygulanır. Gram-Schmidt ortogonalleştirme temel olarak bir matrisin sütunlarının ortogonal olacak şekilde dönüştürülmesi işlemini gerçekleştirir. GS algoritması PCA metodu ile benzer prensibe sahip olup düşük çözünürlüklü multispektral görüntünün ortogonalleştirilmesi esasına dayanmaktadır. Aradaki farklılık ilk GS vektörü yerine pankromatik görüntünün kullanılmasıdır. Bu işlemin ardından yine ters dönüşüm gerçekleştirilerek sonuç görüntü elde edilir.

Brovey dönüşümü multispektral görüntünün düşük çözünürlüklü bantları ve yüksek çözünürlüklü pankromatik bantların matematiksel bir kombinasyonu şeklinde tanımlanır. Brovey dönüşümünün gerçekleştirilmesinde, multispektral görüntünün her bir bandının tüm multispektral görüntü bantlarının toplamına oranı hesaplanır ve ayrı ayrı pankromatik bantla çarpılarak yüksek çözünürlüklü multispektral bantlar elde edilir. Dönüşüm sonrası multispektral görüntülerin yeniden örnekleme en yakın komşuluk, bilinear veya bikübit yöntemlerini kullanarak gerçekleştirilir.

## **2.6 Uzaktan Algılamada Görüntü Dönüşümleri**

Görüntü dönüşümü temel olarak multispektral veya gri tonlamalı görüntüler üzerindeki bilgi içeriğinin bir kısmının veya tamamının yeniden düzenlenerek daha anlamlı hale getirilmesi olarak tanımlanmaktadır (Mather ve Koch, 2011; Richards, 2013). Multispektral görüntünün bir bandını veya birden fazla bandını kullanarak dönüşüm işleminin gerçekleştirilmesinde toplama, çıkarma, çarpma ve bölme işlemlerini içeren aritmetik operasyonlar ve bunlar dışında kalan birçok hesaplama ölçütü kullanabilmektedir.

Dönüşüm sonucunda elde edilen görüntülerin bilgi içeriğinin belirli bir amacın gerçekleştirilmesinde orijinal görüntüye göre daha faydalı olabileceği ifade edilmektedir. Örneğin aynı algılayıcı tarafından belirli bir alan için farklı tarihlerde kaydedilen görüntüler arasındaki fark söz konusu zaman aralığında bölgede meydana gelen değişimlerle ilgili bilgi sağlarken, multispektral görüntünün kızılötesi ve kırmızı bantlarının oranlanması ile canlı bitki örtüsü, biyokütle ve yaprak alan indeksi hesaplamaları için kritik öneme sahip vejetasyon indeks değerleri elde edilebilmektedir.

Görüntü dönüşümü ile elde edilen yeni görüntü veya görüntüler tek başlarına bir uzaktan algılama probleminin çözümlenmesinde kullanılabilecekleri gibi, uydu görüntüleri ile birlikte yardımcı veri olarak değerlendirmeye kullanılabilmektedirler. Tez kapsamında en çok kullanılan görüntü dönüşümlerinden vejetasyon indeksleri, doku özellikleri, temel bileşenler analizi ve ton-doygunluk-yoğunluk (Hue-Saturation-Intensity) dönüşümleri detaylı olarak incelenmiştir.

### 2.6.1 Vejetasyon indeksleri

Uzaktan algılama uygulamalarında yeryüzünün vejetasyon özelliklerinin niteliksel ve niceliksel olarak analizinde vejetasyon indekslerinden yararlanılmaktadır. Söz konusu vejetasyon alanların spektral özellikleri çevresinde bulunan açık renkli toprak, renkli toprak, gölge, nem, çevresel etkiler ve konumsal-zamansal değişimler gibi doğal etmenlerden ötürü karmaşık bir yapıya sahiptir. Vejetasyon alanlarının spektral özelliklerini ortaya çıkarmak ve doğal etmenlerden kaynaklanan hataların azaltılması amacıyla vejetasyon indeksleri kullanılmaktadır. Vejetasyon indeksleri bitki canlılığının belirlenmesinde kullanılan niceliksel ölçümler olarak tanımlanmaktadır (Campbell ve Wynne, 2011). Bir piksel içerisindeki vejetasyon canlılığını veya miktarını ifade eden tek bir değerin hesaplanmasında spektral ölçümlerin toplanması, oranlanması veya çarpılması gibi çeşitli matematiksel dönüşümler yardımıyla hesaplanan vejetasyon indeksleri kullanılmaktadır. Diğer bir ifadeyle vejetasyon indeksleri farklı spektral bantların sahip olduğu yansıma değerlerinin doğrusal kombinasyonları veya oranlarını içerisine alan matematiksel dönüşümlerdir (Payero ve diğ, 2004). Yüksek vejetasyon indeks değerleri önemli oranda sağlıklı bitki olduğunun bir göstergesidir.

Vejetasyon indeksleri başta arazi örtüsü/kullanımı tespitinde olmak üzere ormancılık, rekolte tahmini, biyokütle hesabı ve ürün sağlığı gibi bir çok uygulamada temel veri kaynağı olarak kullanılmaktadır. Günümüze kadar literatürde birçok vejetasyon indeksi tanımlanmış ve uygulamalarda kullanılmıştır (Bannari ve diğ, 1995; Payero ve diğ, 2004; Shamsoddini ve diğ, 2013; Waser ve diğ, 2014). Vejetasyon indeksleri arasında en temel ve en basit olanı iki ayrı spektral banda ait değerlerin birbirine oranlanmasıdır. Bant oranlaması spektrumun ayrı bölümlerini kapsayan spektral yansıma ölçümleri arasındaki oran olarak ifade edilmektedir (Campbell ve Wynne, 2011). Aynı biyofiziksel olayın iki spektral ölçüsü arasında ters bir ilişki olduğunda bant oranlamaları bilgi içeriğinin artırılması veya saklı bilginin ortaya çıkarılmasında büyük avantaj sağlamaktadır. Eğer iki spektral bant benzer spektral özellikler içeriyorsa oranlama sonucunda elde edilecek bilgi çok az olacaktır. Ters durumda ise oranlama sonucu elde edilecek görüntü de önemli derecede kontrast farklılıkları ortaya çıkacaktır. Canlı bitki türlerinin spektral özellikleri elektromanyetik spektrumun kırmızı ve kızılötesi bölgelerinde ters bir ilişkiye sahip olduğundan bant oranlaması stratejisi vejetasyon canlılığı için önemli bir ölçüttür.

Buna karşılık su, su geçirimsiz yüzeyler ve çıplak topraklar gibi yeryüzü özellikleri bitkiler gibi özel bir spektral karakteristiğe sahip olmadığından bant oranlaması sonucunda düşük değerler almaktadırlar. Uzaktan algılama alanında en çok kullanılan vejetasyon indeksi olan normalleştirilmiş bitki fark indeksi (NDVI) bant oranlamasının genişletilmiş bir hali olup, oranlama sonucunda elde edilen değerler arasındaki değişimler belirli istatistiksel özellikleri koruyacak şekilde formüle edilmiştir. NDVI için temel eşitlik kızılötesi (*NIR*) ve kırmızı (*R*) bandın kombinasyonu şeklinde (2.5)'de gösterilmiştir.

$$NDVI = \frac{NIR - R}{NIR + R} \quad (2.5)$$

### 2.6.2 Doku özellikleri

Görüntülerin görsel olarak yorumlanmasında hem spektral hem de konumsal özellikler dikkate alınmaktadır. Spektral özellikler gri tonlu bir görüntü üzerindeki tonlamadaki değişiklikleri tanımlarken, konumsal özellikler görüntü üzerindeki söz konusu ton değişikliklerinin görüntü üzerindeki dağılımlarını tanımlamaktadır. Konumsal özellikler görüntü üzerinde iki tür ilişkiyi incelemektedir. Bunlar görüntüde ilgi duyulan nesnedeki ton değişiklikleri ve görüntüdeki nesneler arasındaki tonal değişimlerdir (Tso ve Mather, 2009). Genellikle doku özellikleri söz konusu iki konumsal ilişkinin belirlenmesinde kullanılmaktadır. Düzenli bir frekansta tekrar eden desen ve/veya desen kombinasyonu olarak tanımlanan doku bir görüntüdeki ilgi duyulan objeleri tanımlanmasında kullanılan önemli bir karakteristiktir. Uzaktan algılamada görüntülerin yorumlanması veya görüntü üzerindeki piksellerin birbirinden ayırt edilmesini kolaylaştırmak amacıyla doku özellikleri hesaplanarak tek başlarına kullanılacağı gibi, uydu görüntüsü ile birlikte yardımcı veri olarak da değerlendirilmeye alınabilmektedir.

Doku özellikleri iki komşu piksel arasındaki uzaklık ve açı ilişkilerinin bir fonksiyonu olarak tanımlanan gri düzey eş oluşum matrislerinden hesaplanmaktadır (Haralick ve diğ., 1973). Gri düzey eş oluşum matrisleri belirli bir mesafede ve yönde bulunan piksel çiftleri arasında gri seviyesinin *i*'den *j*'ye geçen olasılıklarını gösteren iki boyutlu bir matristir. Matrisin hesaplanmasında pikseller arasındaki gri seviyesindeki değişimlerin belirlenmesinde mesafe olarak genellikle 3x3 veya 5x5

gibi pencere boyutu kullanılırken, desen özelliklerinin yönelimine göre genellikle görüntü üzerinde dört yönde (0°, 45°, 90° ve 135°) inceleme yapılır.

Gri düzey eş oluşum matrisi yardımıyla hesaplanabilen doku özellikleri Çizelge 2.1’de formülleri ile birlikte verilmiştir. Tabloda  $i$  satır sayısını,  $j$  sütun sayısını,  $P_{i,j}$  normalleştirilmiş gri-ton konumsal ilişki matrisini,  $\mu$  ve  $\sigma$  ortalama ve standart sapmayı,  $N$  ise görüntüdeki gri düzeylerin sayısını göstermektedir.

**Çizelge 2.1 :** Yardımcı veri seti olarak kullanılan doku özellikleri.

| Doku özelliği        | Formül                                                                                        |
|----------------------|-----------------------------------------------------------------------------------------------|
| Ortalama             | $\sum_{i,j=0}^{N-1} P_{i,j} / N^2$                                                            |
| Varyans              | $\sigma_{i,j}^2 - \sum_{i,j} P_{i,j} (i, j - \mu_{i,j})$                                      |
| Homojenlik           | $\sum_{i,j=0}^{N-1} P_{i,j} / (1 + (i + j)^2)$                                                |
| Zıtlık               | $\sum_{i,j=0}^{N-1} P_{i,j} (i + j)^2$                                                        |
| Farklılık            | $\sum_{i,j=0}^{N-1} P_{i,j}  i - j $                                                          |
| Entropi              | $\sum_{i,j=0}^{N-1} P_{i,j} (-\ln P_{i,j})$                                                   |
| Açısal ikinci moment | $\sum_{i,j=0}^{N-1} P_{i,j}^2$                                                                |
| Korelasyon           | $\rho = \sum_{i,j=0}^{N-1} P_{i,j} ((i - \mu_i)(j - \mu_j) / \sqrt{(\sigma_i^2 \sigma_j^2)})$ |

### 2.6.3 Temel bileşen analizi

Temel bileşen analizi uzaktan algılanmış görüntülerde olduğu gibi birbiriyle korelasyona sahip çok değişkenli veri setlerinin analizi için kullanılan bir yöntemdir. Uzaktan algılama görüntüleri genellikle çok boyutlu bir özellik uzayında temsil edilmektedir. Örneğin Landsat TM görüntüsü 7 spektral banda sahip iken, Hyperion görüntüsü 220 spektral banda sahiptir. Bununla birlikte uzaktan algılanmış görüntülerin sahip olduğu spektral bantlar içerisinde özellikle birbirine komşu bantlar arasında korelasyon vardır. Örneğin, görünür dalga boyu içerisinde kırmızı bantlar negatif bir korelasyon gösterirken, görünür bantlar arasındaki korelasyon pozitifdir. Algılama yapılan spektral aralıklar arttıkça komşu bantlar arasında daha yüksek bir korelasyona sahip olunmaktadır (Liu ve Mason, 2009). Bantlar arasında mevcut olan korelasyon, bilginin gereksiz yere tekrar edildiğini göstermektedir. Bu nedenle

multispektral veri setlerinde verinin geek boyutu genellikle eldeki bant sayısından daha azdır.

Temel bileşen analizi korelasyonlu birçok spektral bantı temsil eden daha az sayıda korelasyonsuz bileşenler tanımlar. Bu işlemin gerçekleştirilmesinde söz konusu veri setinin ortogonal düzleme matematiksel izdüşümü gerçekleştirilir. Bu açıdan ele alındığında temel bileşenler analizinde amaç değişimi ifade edecek yeni bir koordinat sisteminin tanımlanmasıdır (Rencz ve Ryerson, 1999). Dönüşüm sonucunda elde edilen yeni koordinat sistemi birbirine dik eksenlerden oluştuğundan eksenler arası korelasyon sıfır olacaktır. Ham uydu görüntüsünün temel bileşenler analiziyle yapılan dönüşümü sonucunda, elde edilen yeni görüntünün yorumlanabilirliği orijinal görüntüye göre daha yüksek olmaktadır (Lillesand ve diğ, 2007). Bu açıdan ele alındığında temel bileşenler analizi genel olarak bantlar arasındaki korelasyonun yok edilmesi, boyut indirgeme veya azaltma amacıyla kullanılan önemli ve popüler bir analiz tekniğidir.

Uzaktan algılama ve örüntü tanımlama alanında Karhunen-Loeve (K-L) dönüşümleri olarak bilinen temel bileşenler analizi görüntü veri setinin istatistiksel boyutunun tanımlanmasında kullanılmaktadır. Temel bileşen analizinin gerçekleştirilmesinde iki temel işlem adımı vardır (Nag ve Kudrat, 1998). Bunlardan ilki, **(2.6)** yardımıyla görüntünün tüm bantları için varyans-kovaryans matrisi hesaplanmasıdır.

$$Cov(x,y) = \frac{(x_i - \bar{x})(y_i - \bar{y})}{N} \quad (2.6)$$


**(2.6)**'da  $x_i$  herhangi bir banttaki gri değerlerini,  $\bar{x}$  söz konusu banttaki gri değerlerin ortalamasını,  $y_i$  diğer bir bandın gri değerlerini,  $\bar{y}$  bu bandın gri değerler ortalamasını,  $N$  toplam piksel sayısını ve  $Cov(x,y)$  ele alınan iki bant arasındaki kovaryansı göstermektedir. Tüm bantlar için hesaplanan varyans ve kovaryanslar yardımıyla tüm görüntü için varyans-kovaryans matrisi elde edilir. Temel bileşenler analizinde ikinci işlem, oluşturulan varyans-kovaryans matrisinin öz değerleri (eigen value) ve öz vektörlerinin (eigen vectors) hesaplanmasıdır. Öz vektörler her bir temel bileşenin yönelimini tanımlarken, öz değerler her bir temel bileşenin varyanslarını (her bir temel bileşen ekseninin uzunluğunu) belirler. Temel bileşen analizi sonucunda bileşenlere ait hesaplanan varyans değerleri, söz konusu bileşenin bilgi



içeriğini göstermektedir. Temel bileşenler analizi sonucunda elde edilen ilk bileşen en yüksek bilgi içeriğine sahip olup ve genellikle ilk üç bileşen toplam bilginin yaklaşık %90'dan fazlasını içermektedir.

#### 2.6.4 Ton-doygunluk-yoğunluk (Hue-Saturation-Intensity) dönüşümü

Renk uzayları renkleri tanımlamak için kullanılan matematiksel modeller olup, bütün renkleri temsil edecek şekilde 3 boyutlu olarak tanımlanmaktadır. Bunun temel nedeni herhangi bir rengin elde edilmesinde üç değişkene ihtiyaç duyulmasıdır. Renklerin renk uzayındaki konumları söz konusu üç değişkenin alacağı değerlere göre belirlenir. Uygulamalarda en çok bilinen ve kullanılan renk uzayı kırmızı, yeşil ve mavi ana renklerinden oluşan RGB uzayıdır. RGB renk uzayı üç ana rengin bir birim küpün eksenlerinde yer aldığı renk uzayıdır (Şekil 2.7). İnsan gözünün algılayabildiği tüm renkler bu üç ana rengin farklı kombinasyonları şeklindedir. 8 bitlik bir görüntü için RGB sisteminde değerler 0-255 arasında değerler almaktadır. Uzaktan algılama uygulamalarında uzaktan algılanmış görüntülerin analizine fayda sağlaması amacıyla RGB renk uzayından başka bir renk uzayına dönüşüm yapılabilmektedir. Uydu görüntüsünün yorumlanabilirliğini arttırmak amacıyla dönüşüm yapılan renk uzaylarının başında ton-doygunluk-yoğunluk (Hue-Saturation-Intensity, HSI) uzayı gelmektedir (Mather ve Koch, 2011). HSI uzayında ton görünen veya algılanan rengin baskın dalga boyunu, doygunluk bir rengin saflık derecesini veya renk içerisindeki beyaz miktarını, yoğunluk ise bir rengin parlaklığını ya da matlığını göstermektedir. RGB uzayından HSI uzayına dönüşüm neticesinde RGB küpündeki 0-255 aralığındaki değerler, hexacone uzay modelinde doygunluk ve yoğunluk için 0-1 aralığında değerler alırken, ton için  $0^{\circ} - 360^{\circ}$  aralığında açısal değerler almaktadır (Şekil 2.7).



Şekil 2.7 : RGB ve HSI renk uzayları (Mather ve Koch, 2011).

Uzaktan algılanmış görüntülerin RGB uzayından IHS uzayına dönüşümü üç multispektral bant kullanılarak gerçekleştirilir. Dönüşüm işleminin gerçekleştirilmesinde kullanılan eşitlikler aşağıda verilmiştir (Navulur, 2007). Eşitliklerde  $R$ , kırmızı bandı;  $G$  yeşil bandı;  $B$ , mavi bandı gösterirken,  $I$ , yoğunluk;  $S$ , doygunluk ve  $H$  ton değerlerine karşılık gelmektedir.

$$I = (R + G + B) / 3 \quad (2.7)$$

$$S = (1 - 3[\min\{R, G, B\}]) / (R + G + B) \quad (2.8)$$

$$H = \cos^{-1} \frac{(0.5 \times (R - G) + (R - B))}{\left( \left( (R - G)^2 + (R - B)(G - B) \right)^{0.5} \right)} \quad (2.9)$$

## 2.7 Uzaktan Algılamada Görüntü Sınıflandırma

Uzaktan algılanmış görüntülerin analiz ve yorumlanması görüntüler üzerinden yararlı bilgilerin çıkarılarak yeryüzü üzerindeki doğal ve yapay objelerin tanımlanmasını içermektedir. Objelerin birbirinden ayırt edilmesi veya tanımlanmasında, uydular üzerindeki algılayıcılar tarafından kaydedilen ve objelerin sahip olduğu yapısal karakteristiklere bağlı olarak farklılık gösteren yansıma veya yayılma değerleri kullanılmaktadır. Uydu görüntüsünü oluşturan ve en küçük görüntü elemanı olarak tanımlanan pikseller yeryüzünde kapsadıkları alan içerisindeki objelerin yansıma veya yayılma miktarını temsil eden bir parlaklık derecesine sahiptir. Bu nedenle ham halde elde edilen uydu görüntülerinden yeryüzüne ait önemli ve değerli bilgilerin elde edilmesi için çeşitli istatistiksel analizler ve yorumlama tekniklerinden yararlanılmaktadır. Uzaktan algılamada bu amaç doğrultusunda kullanılan en yaygın yöntem uydu görüntülerinin sınıflandırılmasıdır.

Sınıflandırma işleminde temel amaç doğal ve yapay objelere ilişkin spektral özellikleri temsil eden görüntü piksellerinin kullanıcı tarafından belirlenen sınırlı sayıda sınıfa atanmasıdır. Bu açıdan ele alındığında uzaktan algılamada sınıflandırma işlemi objelerin farklı spektral yansıma değerleri esasına dayanarak orijinal görüntüdeki her bir pikselin veya her bir görüntü objesinin arazi örtüsü sınıflarından birisine otomatik olarak kategorize edilmesidir (Lillesand ve diğ., 2007).

Sınıflandırma sonucunda yeryüzünün farklı özelliklerini temsil eden tematik haritalar elde edilmektedir. Söz konusu haritalar, ham halde ve karmaşık yapıda konumsal-spektral bilgi içeren görüntü piksellerini belirli sayıda sınıf ile temsil ettiğinden uydu görüntülerinin yorumlanması ve analizi açısından büyük bir öneme sahiptir (Camps-Valls ve diğ, 2011).

Sınıflandırma işlemi iki temel aşamadan oluşmaktadır (Mather ve Koch, 2011). İlk aşama yeryüzü objelerini temsil eden sınıfların belirlenmesidir. Bu açıdan ele alındığında çalışmanın amacı ve ölçeğine bağlı olarak uzaktan algılamada arazi yüzeylerini temsil eden sınıflar ormanlık alanlar, su kütleleri, bozkır veya diğer arazi örtüsü tipleri şeklinde tanımlanabilmektedir. Sınıflandırma işleminde ikinci aşama sınıflandırılacak piksellere ait sınıf etiketlerinin belirlenmesidir. Söz konusu sınıflandırma aşamaları kullanıcılar tarafından iki adımda gerçekleştirilir:

1. Arazi örtüsünü tanımlayacak sayıda ve kategoride muhtemel sınıfların belirlenmesi,
2. Piksellerin sahip olduğu spektral özellikler esas alınarak sınıflandırma veya karar kuralı olarak tanımlanan bir karar verme yöntemiyle her bir piksele ait sınıf etiketinin tahmin edilmesi.

Uzaktan algılanmış görüntülerin sınıflandırılması karmaşık işlemler içermekte ve birçok faktörün bir arada değerlendirilmesini gerektirmektedir. Görüntü sınıflandırma işlemi süresince uygun bir sınıflandırma yaklaşımının belirlenmesi, sınıflandırıcının eğitimi amacıyla kullanılacak örnek piksellerin tespiti, görüntü ön işleme, özellik çıkarımı, uygun bir sınıflandırma algoritmasının seçimi, sınıflandırma sonrası işlemler ve doğruluk analizi gibi temel işleme adımları takip edilmektedir. Kullanıcı ihtiyaçları, çalışma alanının ölçeği, ekonomik koşullar ve analizi gerçekleştiren kullanıcının tecrübesi kullanılacak uydu görüntüsünün seçimi, sınıflandırma yaklaşımın/algoritmasının belirlenmesi ve sınıflandırma sonuçlarının kalitesini etkileyen önemli faktörler arasındadır (Lu ve Weng, 2007).

Sınıflandırma işleminde genel olarak kontrollü (denetimli) ve kontrolsüz (denetimsiz) sınıflandırma olarak adlandırılan iki yaklaşım kullanılmaktadır. Kontrollü sınıflandırma da farklı spektral grupları temsil eden örnekleme alanları kullanılarak spektral ayırt edilebilirlik incelemekte, buna karşılık kontrolsüz

sınıflandırmada ise spektral olarak ayrılabilir sınıflar belirlenmekte ve bunlardan bilgi elde etme yoluna gidilmektedir.

### **2.7.1 Kontrolsüz sınıflandırma**

Kontrolsüz sınıflandırma yaklaşımının temeli görüntü üzerindeki sınıf etiketi belli olmayan piksellerin analiz edilerek sahip oldukları parlaklık değerlerine göre doğal gruplara ayrılması veya kümelendirilmesi esasına dayanmaktadır. Bu açıdan ele alındığında kontrollü sınıflandırma yaklaşımında görüntü üzerindeki parlaklık değerlerinin dağılımına ilişkin bir istatistiksel değerlendirme söz konusudur (Liu ve Mason, 2009). Kontrollü sınıflandırma yaklaşımının temel çıkış noktası, belirli bir arazi örtüsüne ait piksellerin benzer parlaklık değerlerine sahip olması ve aynı zamanda farklı sınıflar arasında belirli bir dereceye kadar ayırım yapılabilmesidir (Lillesand ve diğ., 2007). Görüntü üzerindeki parlaklık değerleri veya spektral değerler kullanılarak doğal gruplar belirlendiğinden, kontrolsüz sınıflandırma sonucu elde edilen sınıflar (grup veya kümeler) spektral sınıflardır. Bu spektral sınıfların gerçekte hangi arazi örtüsü veya arazi kullanım sınıfına ait olduğu kullanıcı tarafından belirlenmektedir.

Kontrolsüz sınıflandırmada karar kuralı olarak minimum uzaklık kullanır. Pikseller, görüntünün sol üst köşesinden başlanarak soldan sağa ve satır satır analiz edilir. Aday piksel ile her bir küme ortalaması arasında spektral uzaklık hesaplanır ve en yakın kümeye atanır. Öncelikle istenilen sınıf sayısı kadar oluşturulan kümenin ortalaması hesaplanır ve her iterasyondan sonra, her bir kümenin yeni ortalaması hesaplanarak, bu ortalamalar bir sonraki iterasyon kümelerinin tanımlanmasında kullanılır. Kontrolsüz sınıflandırmada küme merkezleri geçici olarak hesaplanarak, piksellerin dahil olacağı sınıflar belirlenir ve bu işlem küme merkezlerinin konumlarında değişim olmayana kadar devam eder. Uygulamada ISODATA, K-ortalama, SOM (Self Organizing Map), ardışık kümeleme ve istatistiksel kümeleme gibi çeşitli kontrolsüz sınıflandırma yöntemleri kullanılmaktadır.

### **2.7.2 Kontrollü sınıflandırma**

Kontrolsüz sınıflandırma yaklaşımının tersine kontrollü sınıflandırmada görüntünün hangi arazi örtüsü sınıflarına ayrılacağı ya da görüntüden hangi sınıfların elde edilmek istenildiği bellidir. Sınıflandırma işleminin gerçekleştirmek amacıyla belirlenen sınıflara ait yeter sayıda örnekleme alanları tespit edilir. Seçilen

sınıflandırma algoritması bu örnek sınıflara ait piksel değerlerini kullanarak sınıflandırmaya esas bir model oluşturulur. Model tüm veri setine (uydu görüntüsüne) uygulanarak görüntüdeki her bir pikselin hangi sınıfa dahil olduğu algoritma tarafından hesaplanır (Lillesand ve diğ., 2007). Üretilen tematik haritaların doğruluğu ve güvenilirliği açısından ele alındığında kontrollü sınıflandırma yaklaşımı uydu görüntülerinin sınıflandırılmasında en çok tercih edilen yaklaşımdır.

Sınıflandırma sonucu üretilen haritalar birçok çevresel ve sosyoekonomik uygulamalar için temel veri kaynağı olduğundan görüntü sınıflandırması uzaktan algılama alanında en yoğun araştırmaların gerçekleştirildiği bir çalışma konusudur. Günümüze kadar uzaktan algılanmış görüntülerin sınıflandırılması ve sınıflandırma doğruluğunun arttırılmasına yönelik birçok kontrollü sınıflandırma algoritması geliştirilmiş ve uygulamalarda kullanılmıştır (Lu ve Weng, 2007; Tso ve Mather, 2009; Li ve diğ., 2014b). Kontrollü sınıflandırma teknikleri piksel-tabanlı (pixel-based), alt-piksel (sub-pixel) ve obje tabanlı (object-based) teknikler olarak üç temel grup altında incelenmektedir (Li ve diğ., 2014b).

#### **2.7.2.1 Piksel tabanlı sınıflandırma**

Geleneksel sınıflandırma tekniği olarak bilinen piksel-tabanlı sınıflandırmada her bir pikselin tek bir arazi örtüsü sınıfını temsil edecek şekilde yalın değerler aldığı ve doğal olarak her bir pikselin tekbir arazi örtüsünü sınıfına karşılık gelecek şekilde sınıflandırıldığı göz önüne alınır. Bu sınıflandırma tekniğinde piksellerin sahip olduğu spektral değerler veya spektral değerlerden üretilen değişkenler (temel bileşenler, vejetasyon indeksleri) piksel tabanlı sınıflandırma işlemi için esas teşkil eden veri setini oluştururlar. Piksel-tabanlı sınıflandırma algoritmaları parametrik veya parametrik olmayan algoritmalar incelemek mümkündür (Lu ve Weng, 2007). Parametrik sınıflandırıcılar sınıflandırma probleminin çözümünde veri setinin normal dağılımda olduğu kabulünü yaparak ortalama vektör, varyans ve kovaryans gibi istatistiksel parametreleri dikkate almaktadır. Literatürde en çok benzerlik, en yakın komşuluk, Mahalonobis uzaklığı, paralel kenar ve en yakın komşuluk olarak adlandırılan sınıflandırıcılar geleneksel istatistiksel tabanlı kontrollü sınıflandırma algoritmaları olarak kabul edilmiş ve uygulamalarda kullanılmıştır.

Birçok uzaktan algılama görüntüsünde benzer spektral özelliklere sahip karmaşık arazi örtüsü tiplerinin olduğu heterojen bir yapı mevcuttur. Bu nedenle söz konusu

görüntüler üzerindeki piksellerin normal spektral dağılımda olduğu kabulü geçersiz olmaktadır. Diğer taraftan düşük konumsal çözünürlüğe sahip veya karışık pikselleri içeren görüntüler üzerinden yeterli sayıda eğitim alanının belirlenmesi güçleşmektedir. Oluşturulan eğitim veri setinin boyutu sınıflandırma sonucu üretilcek tematik haritaların doğruluğunu etki eden önemli bir faktördür. Sınıflandırıcılar verinin veya özellik uzayının sınıflara bölünmesinde farklı metotlar kullandığından, belirli bir sınıflandırma probleminin çözümünde kullanılacak eğitim veri seti boyutu sınıflandırma doğruluğunu etkileyebilmektedir (Foody ve diğ., 2006; Chi ve diğ., 2008). Örneğin en çok benzerlik yönteminde eğitim alanlarını oluşturan sınıflar için olasılık fonksiyonları hesaplanmakta ve buna göre bir pikselin hangi sınıfa daha yakın olduğu belirlenebilmektedir. Diğer taraftan paralel kenar sınıflandırıcısı için histogram yardımıyla sınıflara ait alt ve üst sınırların tanımlanması önem arz ederken, en yakın uzaklık yönteminde sınıfların ortalaması önemlidir.

Parametrik olmayan sınıflandırıcılar veri setinin normal dağılımda olduğu kabulüne dayanmayıp, görüntünün sınıflara ayrılmasında istatistiksel parametrelere ihtiyaç duymamaktadırlar. Bu özellikleri sayesinde birçok çalışmada parametrik sınıflandırıcılara göre daha yüksek sınıflandırma performansı sergiledikleri vurgulanmıştır (Lu ve Weng, 2007). Son yıllarda makine öğrenme algoritması olarak da bilinen destek vektör makineleri, yapay sinir ağları, karar ağaçları ve rastgele orman gibi parametrik olmayan ileri sınıflandırma algoritmaları piksel tabanlı sınıflandırma işleminin gerçekleştirilmesinde başarıyla kullanılmaktadır (Kavzoglu ve Mather, 2003; Kavzoglu ve Colkesen, 2009; Kavzoglu ve Colkesen, 2013; Li ve diğ., 2014b).

#### **2.7.2.2 Alt-piksel tabanlı sınıflandırma**

Piksel tabanlı sınıflandırma tekniğinin aksine alt-piksel tekniği özellikle orta ve düşük konumsal çözünürlüklü uydu görüntülerinde arazi örtüsünün heterojen yapısı nedeniyle her bir pikselin yalın bir arazi örtüsünü temsil etmediği ve birden fazla sınıfa ait yansımaları içerecek şekilde değerler aldığı düşüncesini esas almaktadır (Fisher, 1997; Lu ve Weng, 2007). Literatürde alt-piksel tekniği ile sınıflandırma işleminin gerçekleştirilmesinde bulanık sınıflandırıcılar, yapay sinir ağları, regresyon

modelleme, regresyon ağaçları ve spektral karmaşıklık analizi gibi birçok algoritma kullanılmaktadır (Li ve diğ, 2014b).

### 2.7.2.3 Obje tabanlı sınıflandırma


Geleneksel piksel-tabanlı ve alt-piksel sınıflandırma teknikleri ile karşılaştırıldığında obje-tabanlı sınıflandırma tekniği sınıflandırma işleminin gerçekleştirilmesinde görüntü üzerindeki pikseller yerine benzer özelliklere sahip piksellerin bir araya gelmesi ile elde edilen görüntü objelerini esas almaktadır (Blaschke, 2010; Myint ve diğ, 2011). Obje tabanlı sınıflandırma işlemi görüntü üzerindeki benzer spektral özelliklere sahip piksellerin gruplandırılarak bu pikselleri temsil eden görüntü objelerinin oluşturulması ve pikseller yerine söz konusu objelerin sınıflandırılması esasına dayanmaktadır. Bu açıdan ele alındığında obje tanımlı sınıflandırma işleminde esas olan görüntü üzerindeki pikseller değil piksellerin bir araya gelmesiyle oluşan görüntü objeleridir. Bu sayede görüntü üzerindeki milyonlarca piksel yerine bunları temsil eden objelerin sınıflandırılması söz konusudur. Obje tabanlı sınıflandırma işleminin gerçekleştirilmesinde takip edilen temel işlem adımları Şekil 2.8’de gösterilmiştir.



Şekil 2.8 : Obje tabanlı sınıflandırmada temel işlem adımları.

Genel anlamda segmentasyon büyük objelerin daha küçük parçalara ayrılması anlamına gelmektedir. Obje tabanlı görüntü sınıflandırma işleminde ise benzer spektral özelliklere sahip piksellerin gruplandırılması ve görüntü objelerinin oluşturulması işlemleri görüntü segmentasyonu olarak tanımlanmaktadır. Bu açıdan ele alındığında segmentasyon işlemi küçük parçalara bölme, birleştirme veya yeniden şekillendirme işlemleri olarak da tanımlanabilmektedir.

Segmentasyon işleminin gerçekleştirilmesinde yukarıdan-aşağıya (top-down) ve aşağıdan-yukarıya (bottom-up) olarak bilinen iki temel strateji vardır (Definiens, 2012). Bir parçanın daha küçük parçalara bölünmesi esasına dayanan yukarıdan-aşağıya stratejisi yardımıyla segmentasyon işleminin gerçekleştirilmesinde genel olarak üç segmentasyon metodu kullanılmaktadır. Bunlardan ilki satranç tahtası segmentasyonu (chessboard segmentation) algoritmasıdır. Algoritma bir görüntüyü kullanıcı tarafından belirlenen eşit boyutlu kare formunda parçalara ayırır (Şekil 2.9a).



**Şekil 2.9 :** Obje tabanlı sınıflandırmada a) satranç tahtası ve b) dörtlü ağaç tabanlı segmentasyon algoritmaları.

Dörtlü ağaç tabanlı (quadtree-based) segmentasyon algoritması yukarıdan-aşağı stratejisinin gerçekleştirilmesinde kullanılan diğer bir algoritmadır. Dörtlü ağaç tabanlı algoritma segmentasyon işlemini satranç tahtası algoritmasına benzer bir mantıkla gerçekleştirir. Aralarındaki temel farklılık dörtlü ağaç algoritmasının farklı boyutlarda parçalar üretmesidir. Algoritma homojenlik kriterini sağlamayan her bir




parçayı dört ayrı parçaya ayırır (Şekil 2.9b). Homojenlik kriteri olarak bir parça içerisindeki maksimum renk farklılığı dikkate alınabilir. Bu durumda eğer renk farklılığı belirlenen eşik değerinden fazla ise dörtlü bölünme gerçekleşir. Bu işlem belirlenen homojenlik kriteri sağlanana kadar devam eder. Yukarıdan-aşağıya stratejisinin gerçekleştirilmesinde yararlanılan bir diğer algoritma ise kontrast bölümlenmesi (contrast split) segmentasyonu algoritmasıdır. Algoritma segmentasyon işleminin gerçekleştirilmesinde belirlenen bir eşik değeri dikkate alarak görüntünün, aralarındaki kontrast farkı maksimum olacağı şekilde karanlık ve açık renkli görüntü objelere ayrılması esasına dayanmaktadır.

Segmentasyon işleminin gerçekleştirilmesinde kullanılan ikinci strateji aşağıdan-yukarıya yaklaşımı küçük parçaların belirli kriterler göz önüne alınarak birleştirilerek büyük parçaların elde edilmesi esasına dayanmaktadır. Aşağıdan-yukarıya yaklaşımın gerçekleştirilmesinde çoklu çözünürlük segmentasyonu (multiresolution) algoritması yaygın olarak kullanılmaktadır (Baatz ve Schape, 2000; Benz ve diğ., 2004). Algoritma görüntü üzerindeki ardışık pikselleri veya daha önce segmente edilmiş görüntü objelerini birleştirilmesi işlemini gerçekleştirir. Temel olarak, çoklu çözünürlük segmentasyonu başlangıçta görüntüdeki her bir pikseli bağımsız bir obje olarak değerlendirmeye alır. Daha sonra her bir görüntü objesi veya piksel belirli bir homojenlik kriteri esas alınarak komşu pikseller ile birleştirilerek daha büyük görüntü objeleri elde edilir. Söz konusu homojenlik kriteri spektral ve şekil kriterlerinin birleşimi olarak ifade edilen ölçek parametresi ile belirlenir. Ölçek parametresi arttıkça daha büyük görüntü objeleri üretilirken, küçük parametre değerleri için daha küçük ve fazla sayıda görüntü objeleri elde edilir. Çoklu çözünürlük segmentasyonu algoritmasının kullandığı homojenlik kriteri görüntü objelerinin kendi içerisindeki homojenliğini veya heterojenliğini ölçer. Söz konusu kriter renk ve şekil özelliklerinin birleşimi ile belirlenmektedir. Renk homojenliği spektral renklerin standart dağılımını esas alır. Şekil homojenliği ise objelerin şekillerindeki sapmaları dikkate almaktadır. Homojenlik kriteri renk ve şekil kriterlerinin ağırlıklandırılması ile belirlenebilmektedir. Sonuç olarak çoklu çözünürlük algoritması benzer değerlere sahip pikselleri bir araya getirerek objeleri oluşturur. Homojen alanlar daha geniş objelerle gösterilirken, karmaşık yapıdaki pikselleri içeren heterojen alanlar daha küçük objelerle temsil edilir.

Johnson (2013), obje tabanlı sınıflandırma yaklaşımda en önemli problemde birinin oluşturulacak görüntü objelerinin ortalama boyutunu belirleyen görüntü segmentasyon parametrelerinin tespiti noktasında yaşandığını vurgulamıştır. İlgi duyulan arazi örtüsü özelliğinden daha küçük boyutta görüntü objeleri üreten segmentasyon parametreleri kullanıldığında görüntü objeleri için hesaplanan spektral olmayan bilgilerin (örneğin şekil ve geometri) sınıflandırma doğruluğuna katkı sağlayacak düzeyde faydalı bilgiler sağlamayacağını ifade etmiştir. İlgi duyulan yeryüzü nesnesinden daha büyük boyutta görüntü objesi üretecek şekilde segmentasyon parametrelerinin belirlenmesi durumunda ise birden fazla sınıfa ait piksellerin bir obje içerisine dahil edilmesi söz konusu olmaktadır. Bu nedenle segmentasyon işlemi öncesinde optimum segmentasyon parametrelerinin belirlenmesi esastır. Çoklu çözünürlük segmentasyonu algoritma yardımıyla görüntü segmentasyonun gerçekleştirilmesinde temel olarak ölçek, şekil ve yoğunluk olarak adlandırılan 3 farklı parametrenin kullanıcı tarafından belirlenmesi gerekmektedir. Bunlardan en önemlisi ölçek parametresi olarak ifade edilmektedir (Myint ve diğ., 2011). Bunun en önemli nedeni seçilecek ölçek parametresinin direkt olarak segmentasyon sonucu oluşturulacak görüntü objelerinin boyutu ile ilişkili olmasıdır. Çok büyük ölçek parametresi kullanılması neticesinde görüntüdeki birçok detay kaybolmakta dolayısıyla üretilen görüntü objeleri farklı arazi örtüsü/kullanımı sınıfına ait pikselleri içerisine alabilmektedir. Bu durum özellikle hatalı sınıflandırmalara dolayısıyla sınıflandırma doğruluğunun önemli düzeyde azalmasına neden olabilmektedir. Diğer taraftan ölçek parametresinin çok küçük seçilmesi beraberinde görüntü üzerinde olması gerekenden çok daha fazla sayıda obje oluşmasına, dolayısıyla sınıflandırma için gereken işlem süresinin artmasında neden olmaktadır.

Ölçek parametresi ile ilgili bir başka husus ise tüm görüntü için tek bir ölçek parametresi tanımlanması ile ilgilidir. Bu noktada karşılaşılan en önemli problemlerden birisi de farklı arazi örtüsü/kullanım sınıflarının farklı ölçeklerde daha iyi sınıflandırılmasıdır (Johnson, 2013). Tüm görüntü için en uygun ölçek parametresi belirlense dahi tek bir ölçek parametresinin kullanılması durumunda bazı arazi örtüsü sınıfları için optimum segmentasyon gerçekleşmemektedir. Bu problemin çözümünde farklı ölçekli parametrelerinin kullanılmasına yönelik çalışmalar mevcuttur (Trias-Sanz ve diğ., 2008; Blaschke, 2010; Anders ve diğ., 2011;

Myint ve diğ, 2011; De Pinho ve diğ, 2012; Zhang ve diğ, 2014). Görüntü üzerindeki doğal ve yapay nesneler büyüklükleri ve yoğunluklarına göre değişiklik göstermektedir. Şekil 2.10a'dan da görüleceği üzere ölçek parametresi 100 olarak belirlendiğinde bir görüntü objesi içerisinde birden çok fıstık çamı ağacının, ağaçlara ait gölge alanların ve ağaçların zeminindeki bozkır alanların dahil edildiği görülmektedir. Diğer bir ifadeyle bir tek sınıfı temsil edecek görüntü objesi yerine birden çok sınıfı içerisine alan karmaşık yapıdaki görüntü objesi elde edilmiştir. Ölçek parametresi 50 olarak belirlendiğinde fıstık çamı, gölge ve bozkır alanlarının ayrı görüntü objeleri içerisinde kaldığı görülmektedir. Ölçek parametresi 50'den 20'ye düşürüldüğünde ise segmentasyon sonucu üretilen görüntü objesi sayısındaki artış net olarak gözükmemekte ve aynı sınıfın birden çok obje ile temsil edildiği görülmektedir.



**Şekil 2.10 :** Farklı ölçek parametreleri kullanılarak gerçekleştirilen segmentasyon işlemi.

Buna karşın bina ve yol gibi sürekli özellikler gösteren objeler küçük ölçek parametresi kullanımıyla yüzlerce obje ile tanımlanmak durumunda kalırken, büyük ölçek parametresi ile birkaç görüntü objesi ile temsil edilebilmektedir. Örneğin Şekil 2.10b’de ölçek parametresinin 100 olarak seçildiği segmentasyon işlemi sonucunda kiremit çatıya sahip bir binanın birkaç görüntü objesi ile temsil edildiği görülmektedir. Ölçek parametresinin arttırılması ile söz konusu bina çatısını temsil eden görüntü objesi sayısındaki artış açıkça görülmektedir. Bu bina çatısı için ölçek parametresi 20 olarak seçildiğinde, süreklilik gösteren bina çatısı çok fazla obje ile tanımlanabilmektedir. Bu durum oluşturulan bina objelerinin bazı kısımlarının benzer spektral özelliklere sahip diğer sınıflarla karıştırılmasına, dolayısıyla hatalı sınıflandırılmasına neden olmaktadır. Benzer durum yine süreklilik özelliği gösteren ve doğrusal karakteristiğe sahip yol alanları içinde geçerlidir. Şekil 2.10c’den de görüleceği üzere ölçek parametresi 20 olarak seçildiğinde doğrusal özelliğe sahip yol kaplaması yüzlerce farklı görüntü objesi ile temsil edilmek zorunda kalmaktadır. Buna karşın büyük ölçek parametreleri ile aynı yol kaplaması birkaç veya sınırlı sayıda görüntü objesi ile temsil edilebilmektedir. Bu nedenle özellikle yüksek çözünürlüklü uydu görüntülerinin obje tabanlı yaklaşımla sınıflandırılmasında optimum ölçek parametresinin belirlenmesi hem sınıflandırma sonucu üretilen tematik haritanın doğruluğu hem de tematik harita üretimi ve sınıflandırma işleminin gerçekleştirilmesi için gerekli olan işlem süresi açısından kritik bir öneme sahiptir.

Segmentasyon işleminin ardından elde edilen her bir görüntü objesi için objelerin birbirinden ayırt edilmesi amacıyla objelere özgü özellikler tanımlanır. Her bir objenin temsil ettiği piksellere ilişkin ortalama, standart sapma, minimum ve maksimum değerler gibi temel spektral bilgiler özellik olarak tanımlanabileceği gibi objelerin alanları, uzunlukları, genişlikleri veya yönelimleri gibi konumsal karakteristikleri de özellik olarak tanımlanabilmektedir. Konumsal ve spektral özelliklerin yanında gri düzey oluşum matrisi yardımıyla hesaplanan ortalama, varyans, homojenlik, zıtlık, farklılık, entropi, ikinci moment ve korelasyon gibi doku özellikleri de objelere ait özellikler olarak tanımlanabilmektedir. Bununla birlikte obje tabanlı sınıflandırma yaklaşımında sınıflandırmaya konu görüntü objeleri olduğundan objeler arasındaki ilişkiler de (objeler arasındaki komşuluk, yakınlık, obje uzunluğu, obje alanı vb.) özellik olarak değerlendirmeye alınabilmektedir.

Segmente edilmiş görüntü üzerindeki objelere ait özelliklerin tanımlanmasının ardından bir sonraki adım sınıflandırma aşamasıdır. Sınıflandırma öncesinde kontrollü sınıflandırma için ön koşul olan eğitim ve test veri setlerinin oluşturulması işlemi gerçekleştirilir. Söz konusu veri setleri önceden belirlenen arazi örtüsü/kullanımı sınıflarını temsil eden objelerden oluşmaktadır. Daha sonra bir kontrollü sınıflandırma algoritması yardımıyla oluşturulan eğitim ve test veri setleri kullanılarak sınıflar arasındaki ayrımın en yüksek doğrulukta gerçekleştirildiği sınıflandırma modeli üretilir. Test veri seti ile performansı belirlenen model, hangi sınıfa ait olduğu bilinmeyen diğer görüntü objelerinin sınıflandırılmasında kullanılır. Sınıflandırma sonucunda, obje tabanlı yaklaşımla üretilen segmentlerin (görüntü objelerinin) önceden belirlenen bir arazi örtüsü/kullanımı sınıfına atandığı tematik harita üretilir.


## **2.8 Sınıflandırma Algoritmaları**

Çok yüksek çözünürlüklü uydu görüntüleme algılayıcılarının kullanılabilirliğinin artması arazi kullanımı ve arazi örtüsü türleri hakkında ayrıntılı bilgi elde edilmesi noktasında yeni bir veri kaynağı sağlamıştır. Korelasyonlu ve spektral olarak benzer karakteristiklere sahip pikselleri içeren yeni nesil yüksek çözünürlüklü uydu görüntüleri üzerinden doğruluğu yüksek tematik harita üretimi için literatürde çeşitli gelişmiş sınıflandırma teknikleri ve sınıflandırıcılar önerilmiştir. Yüksek çözünürlüklü uydu görüntülerinin kullanılması birçok doğal ve yapay nesnenin bir arada değerlendirilerek benzer spektral özelliklere sahip nesnelerin birbirinden ayırt edilmesini gerektirmektedir. Diğer bir ifadeyle yüksek çözünürlüklü uydu görüntüleri yardımıyla arazi örtüsü/kullanımının belirlenmesinde benzer spektral özelliklere sahip karmaşık yapıdaki piksellerin değerlendirilmesi ve sınıflandırılması söz konusudur. Literatürde sınıflandırma işleminin gerçekleştirilmesi ve tematik harita üretimine yönelik birçok algoritma önerilmiştir (Lu ve Weng, 2007). Bunlar arasında hesaplama açısından hızlı ve matematiksel olarak kolay anlaşılabilen en çok benzerlik yöntemi yaygın bir kullanıma sahiptir. Yöntem uygulama açısından pratik olmasına rağmen görüntü üzerindeki piksellerin normal dağılımda olduğu kabulünü esas almaktadır. Bu nedenle yöntem birbirine benzer spektral özelliğe sahip karmaşık ve homojen olmayan yapıdaki piksellerin ayırt edilmesi noktasında yetersiz

kalmaktadır. Bu problemin çözümüne yönelik olarak son yıllarda ileri sınıflandırma teknikleri kullanılmaya başlanmıştır.

### 2.8.1 En yakın komşuluk

En temel örnek tabanlı öğrenme algoritmalarından birisi olan en yakın komşuluk (EYK) algoritması, uzaktan algılama alanında geleneksel sınıflandırıcı olarak kabul edilen parametrik bir algoritmadır. EYK algoritması öncelikli olarak eğitim kümesi içerisindeki sınıfları temsil eden ortalama değer vektörleri hesaplar. Daha sonra sınıflandırılmak istenen aday pikselin hesaplanan sınıf ortalama vektörleri arasındaki spektral uzaklıklar hesaplanır. Hesaplanan spektral uzaklıklara göre aday piksel en yakın mesafedeki örnek sınıfa atanır (Lillesand ve diğ, 2007). Şekil 2.11’de sınıf etiketi belli olmayan aday bir pikselin 4 sınıf için hesaplanan ortalama vektörlere olan spektral uzaklıkları bir çizgi ile gösterilmiştir. Şekle göre aday pikselin sınıf etiketi hesaplanan spektral uzaklıklardan en yakın mesafede olan sınıf etiketi olarak belirlenir.



**Şekil 2.11 :** En yakın komşuluk algoritması ile sınıflandırma problemi çözümü.


Sınıflara ait ortalama vektörler ile aday piksel arasındaki spektral uzaklık (2.10)’da verilen Öklit uzaklığı esasına dayanmaktadır. Eşitlikte;  $k$ , bant sayısını (boyutu);  $i$ , belirli bir bandı;  $c$ , belli bir sınıfı;  $X_{xyi}$ ,  $i$ . banttaki pikselin  $x, y$  değerlerini;  $\mu_{ci}$ ,  $i$  bandındaki  $c$  sınıfına ait örnekler için değerlerin ortalamasını;  $d_{xyc}$ , aday piksel  $x, y$ ’nin  $c$  sınıfına ait ortalama vektöre olan spektral uzaklığı olarak ifade edilebilir.

$$d_{xyc} = \sqrt{\sum_{i=1}^k (\mu_{ci} - X_{xyi})^2} \quad (2.10)$$

En yakın komşuluk algoritması matematiksel olarak kolay anlaşılabilir, basit ve hesaplama zamanı açısından hızlı olan bir sınıflandırma algoritmasıdır. Önemli avantajlarına rağmen EYK algoritması, görüntü üzerindeki objelerin spektral olarak birbirine çok yakın değerlere sahip olduğu ve yüksek varyans değerlerine sahip veri setleri için düşük doğrulukta sonuçlar üretebilmektedir (Lillesand ve diğ, 2007).

### 2.8.2 Destek vektör makineleri

Destek vektör makineleri (DVM) uzaktan algılanmış görüntülerin sınıflandırılması amacıyla son yıllarda yaygın bir şekilde kullanılan ve sınıflandırmadaki etkinliği birçok çalışmada ortaya konulan bir sınıflandırma algoritmasıdır (Huang ve diğ, 2002; Camps-Valls ve Bruzzone, 2009; Kavzoglu ve Colkesen, 2009; Mountrakis ve diğ, 2011). DVM parametrik olmayan ve istatistiksel öğrenme teorisine dayanan yeni nesil bir sınıflandırma algoritmasıdır. Algoritmanın temel çalışma prensibi iki sınıfa ait pikselleri birbirinden optimum şekilde ayırabilen bir hiperdüzlemin belirlenmesi esasına dayanmaktadır (Vapnik, 1995). DVM algoritmasının geliştirilmesinde göz önüne alınan temel sınıflandırma problemi Şekil 2.12’de gösterildiği üzere iki sınıfa içeren ve doğrusal bir yapıya sahip veri setinin sınıflandırılmasıdır.



**Şekil 2.12 :** Destek vektör makineleri ile iki sınıflı veri setinin sınıflandırılması.

Şekilde turuncu daireler ile temsil edilen pikseller A sınıfını, yeşil üçgenler ile temsil edilen pikseller ise B sınıfını göstermektedir. Şekilde mavi renkle gösterilen çizgiler

arasındaki uzaklık sınır olarak adlandırılmaktadır. İki sınıfa üye pikseller arasındaki söz konusu uzaklığı maksimum yapan sadece bir sınır pozisyonu vardır. Mavi çizgiler üzerinde A ve B sınıflarına ait sarı renkle gösterilen pikseller birbirlerine en yakın mesafede bulunan pikseller olup destek vektörleri olarak adlandırılmaktadır.

Problem çözümü için en az iki destek vektörünün bulunması şarttır, ancak uygulamada çok daha fazla sayıda destek vektörü dikkate alınmaktadır (Mather ve Koch, 2011). Sınırın tam ortasından geçen kırmızı çizgi optimum hiperdüzlem olarak tanımlanmaktadır. Şekil 2.12'deki problem göz önüne alındığında sınıf etiketi belli olmayan aday piksele ait sınıf etiketi DVM algoritmasıyla belirlenen optimum hiperdüzlem göz önüne alınarak tespit edilir. Aday piksel şekilde optimum hiperdüzlemin yönelimine göre sağ üst kısmında yer alıyorsa A sınıfına, sol alt tarafta kalıyorsa B sınıfına atanmaktadır. Söz konusu problemde de görüleceği üzere DVM ile sınıflandırma işleminin gerçekleştirilmesinde sadece destek vektörleri olarak adlandırılan pikseller dikkate alınmakta, diğer pikseller sınıflandırma sonucuna etki etmemektedirler. Bu özelliği destek vektör makinelerinin sınırlı sayıda eğitim veri seti için diğer algoritmalara göre daha üstün performans göstermesinin en önemli nedeni olarak ifade edilmektedir (Foody ve diğ, 2006; Kavzoglu ve Colkesen, 2012).

Destek vektör makinelerinde temel alınan eşitlikler en basit sınıflandırma problemi olan iki sınıfa ait doğrusal olarak ayrılan veri setleri göz önüne alınarak geliştirilmiştir. Söz konusu problemde, iki sınıflı  $k$  sayıda örnekten oluşan doğrusal yapıdaki bir eğitim verisi seti  $\{x_i, y_i\}$ ,  $i = 1, \dots, k$ , şeklinde tanımlanmaktadır. Burada  $x_i \in R^N$  olup eğitim veri setindeki multispektral bantlara ait değerleri,  $y \in \{-1, +1\}$  ise sınıf etiketlerini göstermektedir. Hiperdüzleme ait ağırlık vektörü  $w$  ve hiperdüzlemin uzayda yönelimini tanımlayan  $b$  sayısal büyüklüğünün hesaplanmasıyla iki sınıfı birbirinden ayıran hiperdüzlem belirlenebilmektedir. Söz konusu hiperdüzlem (2.11) ve (2.12) eşitlikleri yardımıyla hesaplanır.

$$w \cdot x_i + b \geq +1 \quad \text{her } y = +1 \text{ için} \quad (2.11)$$

$$w \cdot x_i + b \leq -1 \quad \text{her } y = -1 \text{ için} \quad (2.12)$$

Bu iki eşitlik tek bir eşitlik ile ifade edilecek olursa hiperdüzlem için genel eşitlik,



$$y_i(w \cdot x_i + b) - 1 \geq 0 \quad (2.13)$$

şeklinde elde edilir. Elde edilen hiperdüzlem standart bir hiperdüzlem olmakla birlikte,  $w$  ve  $b$  parametrelerinin değiştirilmesi veya ölçeklenmesi sonucunda birçok hiperdüzlem tanımlanabilmektedir (Osuna ve diğ, 1997).

$(x_1, y_1), \dots, (x_k, y_k)$   $x_i \in R^N, y_i \in \{-1, +1\}$  şeklinde verilen bir veri setinin doğru bir şekilde sınıflandırılması için maksimum sınıra sahip hiperdüzlemin (optimum hiperdüzlem) belirlenmesi ön koşuldur. Destek vektörleri arasındaki sınırın maksimum hale getirilmesi ağırlık vektörünün ( $w$ ) minimum hale getirilmesi ile elde edilmektedir. Bu durumda maksimum sınıra sahip hiperdüzlem;

$$\min_{w, b} \frac{1}{2} \|w\|^2 \quad (2.14)$$

koşulu ile


$$y_i(w \cdot x_i + b) - 1 \geq 0 \quad i = 1, \dots, k \quad (2.15)$$

eşitliğinin çözümü ile belirlenir. Söz konusu koşul ve eşitlik ile ifade edilen doğrusal olmayan optimizasyon problemi Lagrange fonksiyonu ve Lagrange çarpanları ( $\lambda_i, i = 1, \dots, k$ ) kullanılarak çözülebilmektedir. Sonuç olarak DVM ile iki sınıflı doğrusal veri setini birbirinden ayıran optimum hiperdüzleme ilişkin karar fonksiyonu (2.16) ile ifade edilir (Vapnik, 1995; Osuna ve diğ, 1997, Tso ve Mather, 2009).

$$f(x) = \text{sign} \left( \sum_{i=1}^k \lambda_i y_i (x \cdot x_i) + b \right) \quad (2.16)$$

Uzaktan algılanmış görüntülerin sınıflandırılması probleminde de olduğu gibi doğrusal olarak ayıramayan verilerin sınıflandırılmasında hiperdüzlemlerin doğrusal eşitliklerle belirlenmesi mümkün değildir. Bu problemin çözümü için, doğrusal olarak ayrılabilen veriler için oluşturulan eşitlikler doğrusal olarak ayıramayan veriler için genelleştirilmiştir. Doğrusal olmayan verilerin sınıflandırılması problemi Şekil 2.13'den de görüleceği üzere pozitif değerler alan ve sınıflandırma hatalarını

ifade eden değişkenlerin ( $\xi_i$ ) tanımlanması ve optimizasyon modeline eklenmesi ile çözülebilmektedir (Cortes ve Vapnik, 1995).



**Şekil 2.13 :** Ayrım yapılamayan veri setleri için hiperdüzlemler.

Hatalı sınıflandırılan veriler için tanımlanan değişkenlerde dikkate alındığında, optimum hiperdüzlem destek vektör makineleri arasındaki sınırı maksimum yaparken hatalı sınıflandırılmış piksellerin sayısını minimum yapacak şekilde belirlenmelidir (Pal ve Mather, 2005). Söz konusu maksimum ve minimum koşulları arasındaki denge, kullanıcı tarafından belirlenen düzenleme parametresi ( $C$ ) yardımıyla sağlanmaktadır. Düzenleme parametresi,  $\xi_i$  değişkeninin büyük değerler alması sonucunda ortaya çıkan çözümlere ceza vererek minimum koşulunun  $(1/2)\|w\|^2$  sağlanmasını gerçekleştirmektedir. Bu durumda doğrusal olmayan veriler için optimizasyon problemi:

$$\min_{w, b, \xi_1, \dots, \xi_k} \left[ \frac{1}{2} \|w\|^2 + C \sum_{i=1}^k \xi_i \right] \quad (2.17)$$


$$y_i (w \cdot x_i + b) - 1 + \xi_i \geq 0 \quad (2.18)$$

$$\xi_i \geq 0, \quad i = 1, \dots, k \quad (2.19)$$

şeklinde ifade edilir. Langrange fonksiyonu kullanılarak doğrusal olmayan veri setleri için elde edilen karar fonksiyonu (2.20)'de verilmiştir.

$$f(x) = \text{sign} \left( \sum_i \lambda_i y_i \phi(x) \cdot \phi(x_i) + b \right) \quad (2.20)$$

Bu eşitlikten de anlaşılacağı üzere doğrusal olarak verilerin ayırt edilemediği durumlarda verileri daha yüksek boyutlu bir uzaya taşıyarak çözümlemek için doğrusal olmayan fonksiyonlar kullanılmaktadır. (2.20)'de verilen  $\phi(x) \cdot \phi(x_i)$  skaler çarpımının yerine  $K(x_i, x_j) = \phi(x) \cdot \phi(x_i)$  şeklinde ifade edilen Kernel fonksiyonları kullanılarak söz konusu dönüşümler yapılabilir (Vapnik, 1995, Mathur ve Foody, 2008). Kernel fonksiyonları doğrusal olmayan dönüşümler yapılabilmekte ve verilerin yüksek boyutta doğrusal olarak ayrılabilmesine imkan sağlamaktadır (Şekil 2.14).



**Şekil 2.14 :** Doğrusal olarak ayrılamayan veri setlerinin DVM ile sınıflandırılması.


Literatürde birçok kernel fonksiyonu tanımlanmış olmasına rağmen, radyal tabanlı fonksiyon (RTF) problem çözümündeki etkinliği ve yüksek sınıflandırma doğruluğu üretmesi nedeniyle en çok tercih edilen kernel fonksiyonudur (Huang ve diğ, 2002; Melgani ve Bruzzone, 2004; Pal ve Mather, 2005; Kavzoglu ve Colkesen, 2009; Mather ve Koch, 2011). RTF kerneli kullanımında kullanıcı tarafından belirlenen iki parametre (düzenleme parametresi ve kernel genişliği) söz konusudur. Söz konusu parametrelerin alacağı değerler DVM ile elde edilecek sınıflandırma doğruluğunu direkt olarak etkilemektedir (Camps-Valls ve Bruzzone, 2009; Kavzoglu ve Çölkesen, 2010). Bu nedenle DVM'nin eğitimi sırasında optimum parametre değerlerinin belirlenerek sınıflandırma işlemi gerçekleştirilmelidir.

### 2.8.3 Karar ağaçları

Karar ağaçları (KA) son yıllarda literatürde yaygın kullanımı olan bir sınıflandırma ve örüntü tanımlama algoritmasıdır (Rogan ve diğ, 2008; Çölkesen, 2009; Goltz ve diğ, 2009; Kavzoğlu ve Çölkesen, 2010; Rodriguez-Galiano ve Chica-Rivas, 2014). Algoritma ağaç yapılarının oluşturulmasında kullanılan karar kurallarının anlaşılabilir ve sade olması nedeniyle en çok tercih edilen sınıflandırma algoritmalarındandır. KA sınıflandırıcısı bir sınıflandırma problemini tabakalı veya katmanlı bir yapıya dönüştürerek sınıfları birbirinden ayırt etme prensibini esas almaktadır (Swain ve Hauska, 1977; Mather ve Koch, 2011). Diğer bir ifadeyle algoritma, uzaktan algılanmış görüntüleri de içerisine alan karmaşık yapıdaki veri setlerinin sınıflandırılması problemini aşamalı bir hale getirerek basit bir karar verme işlemi gerçekleştirir (Safavian ve Landgrebe, 1991).

Bir karar ağacının temel yapısı Şekil 2.15’de görüldüğü üzere düğüm, dal ve yaprak olarak adlandırılan üç temel kısımdan oluşur. Bu ağaç yapısında her bir öznitelik (uydu görüntüsü için bant değeri) bir düğüm tarafından temsil edilir. Dallar ve yapraklar ağaç yapısının diğer elemanlarıdır. Ağaçta en son kısım yaprak en üst kısım ise kök olarak adlandırılır. Kök ve yapraklar arasında kalan kısımlar ise dal olarak ifade edilir (Quinlan, 1993). Eğitim verilerine ait öznitelik bilgilerinden yararlanılarak bir karar ağacı yapısı oluşturulmasında temel prensip verilere ilişkin bir dizi sorular sorulması ve elde edilen cevaplar doğrultusunda hareket edilerek en kısa sürede sonuca gidilmesi olarak ifade edilebilir. Bu şekilde karar ağacı sorulara aldığı cevapları toplayarak karar kuralları oluşturur. Ağacın ilk düğümü olan kök düğümünde verilerin sınıflandırılması ve ağaç yapısının oluşturulması için sorular sorulmaya başlanır ve dalları olmayan düğümler ya da yapraklar bulunana kadar bu işlem devam eder (Pal ve Mather, 2003).

Şekilde 2.15’de Landsat TM görüntüsünün kırmızı, yeşil, mavi ve NIR bantları kullanılarak orman, su ve toprak sınıflarının karar ağaçları ile sınıflandırılması problemi ele alınmıştır. Karar ağacı algoritması sınıflara ait bant değerlerinden yola çıkılarak ağaç yapısının oluşumunda başlangıç noktası olarak kabul edilen kök düğümde hangi bandın bulunacağını belirler. Diğer bir ifadeyle kök düğüme esas olacak bant seçilerek ağaç gelişimi veya dallanmasına başlanır.



**Şekil 2.15 :** Üç sınıfa sahip dört bantlı veri seti için oluşturulan karar ağacı yapısı.

Ağaç yapısındaki dallanmanın hangi kritere veya kıstasa göre yapılacağı ya da hangi bant değerlerine göre ağaç yapısının oluşturulacağı ağacı yapısının oluşturulmasındaki en önemli işlem adımıdır (Tso ve Mather, 2009; Mather ve Koch, 2011). Literatürde bu problemin çözümünde kullanılan birçok ölçüt bulunmaktadır. Bunlardan en önemlileri bilgi kazancı ve bilgi kazanç oranı (Quinlan, 1993), Gini indeksi (Breiman ve diğ, 1984), Towing kuralı (Breiman ve diğ, 1984), ve Ki-kare olasılık tablo istatistiği (Mingers, 1989) yaklaşımlarıdır. Bilgi kazancı ve bilgi kazanç oranını yaklaşımda dallanma için özellik seçiminde esas alınan ölçüt bir sistemdeki düzensizliği ya da belirsizliği ifade eden entropidir. Tek değişkenli karar ağaçlarında ID3 algoritması bilgi kazancı yaklaşımını kullanmaktadır. Bu algoritmanın geliştirilmiş hali olan C4.5 algoritması bölünme bilgisi kavramı ile bilgi kazancından yararlanarak hesaplanan kazanç oranı yaklaşımını kullanmaktadır. Örnek problemde bilgi kazancı algoritması kök düğüm için kırmızı bantı seçmiş ve ağacın dallanması bu bantın değerlerinden yola çıkılarak başlamıştır. Bu noktadan bir yaprağa ulaşıncaya kadar ara düğümlerin seçilmesi veya ağacın dallanması aynı prensipten hareketle gerçekleştirilir. Şekildeki ağaç yapısı göz önüne alındığında, sınıf etiketi belli olmayan bir piksel, kırmızı bantta 48,5 değerinden küçük veya eşit değere sahipse ve aynı pikselin kırmızı banttaki parlaklık değeri 29,5’den küçük veya eşitse söz konusu piksel su sınıfındadır sonucuna ulaşılır.

#### **2.8.4 Toplu öğrenme algoritmaları**

Son yıllarda tek bir sınıflandırıcı kullanılması yerine birden çok sınıflandırma algoritmasının bir arada kullanıldığı toplu öğrenme yaklaşımı uzaktan algılanmış görüntülerin sınıflandırılmasını problemini de içerisine alan birçok uygulama da kullanılmaktadır. Toplu öğrenme yaklaşımı tek bir sınıflandırıcı yerine birden çok sınıflandırıcıyı içerecek şekilde bir sınıflandırıcı kümesinin oluşturulması ve küme içerisindeki sınıflandırıcıların tahminlerinden yola çıkılarak sınıf etiketi belli olmayan piksellerin sınıflandırılması esasına dayanmaktadır (Dietterich, 2000). Toplu öğrenme veya sınıflandırıcıların birleştirilmesi, yeniden örneklenen eğitim setleri ile sınıflandırıcıların ayrı ayrı eğitilmesi ve sonuçta ortaya çıkan tahminler ile sınıflandırma işleminin gerçekleştirilmesi işlemlerini içermektedir. Literatürde toplu öğrenme algoritmaları kullanımı ile sınıflandırma performansında önemli derecede artış olduğu vurgulanmaktadır (Opitz ve Maclin, 1997; Dietterich, 2000, Pal ve Mather, 2003, Maudes ve diğ., 2012). Günümüze kadar toplu öğrenme algoritması olarak başta hızlandırma, torbalama, rastgele orman ve dönüşümlü orman olmak üzere birçok algoritma geliştirilmiştir (Du ve diğ., 2012; Kavzoglu ve Colkesen, 2013; Xia ve diğ., 2014; Diez-Pastor ve diğ., 2014).

##### **2.8.4.1 Hızlandırma algoritması**

Hızlandırma algoritmasının eğitim veri setindeki her bir piksele ağırlık verilmesi esasına dayanmaktadır (Freund ve Schapire, 1996; Tso ve Mather, 2009; Çölkesen ve Kavzoglu, 2009). Eğitim veri seti içerisindeki her bir pikselin ağırlıkları başlangıçta eşit olarak alınır. Daha sonra toplu öğrenme kümesi içerisindeki her bir sınıflandırıcı için eğitim verisindeki piksellere ait sınıf etiketleri tahmin edilir. Tahmin edilen sınıf etiketleri ile bilinen sınıf etiketleri karşılaştırılarak, eğitim veri seti içerisinde hangi piksellerin hatalı sınıflandırıldığı tespit edilir. Bir sonraki adımda eğitim veri seti içerisinde hatalı sınıflandırılan bu piksellere ait ağırlıklar artırılarak sınıflandırma işlemi tekrar edilir. Hatalı sınıflandırılan piksellerin ağırlıklarının artırılması ile sınıflandırıcıların bu elemanlar üzerine odaklanması sağlanır. Hızlandırma algoritması bu iteratif yaklaşımla eğitim veri seti içerisinde doğru sınıflandırılan pikseller yerine hatalı sınıflandırılan piksellere yoğunlaşarak sınıflandırma doğruluğunu artırılmasını amaçlamaktadır.

Literatürde hızlandırma yöntemiyle sınıflandırıcıların birleştirilmesinde en çok tercih edilen algoritma Adaboost algoritmasıdır (Freund ve Schapire, 1996; Tso ve Mather, 2009; Çölkesen, 2009; Canty, 2014). Adaboost toplu öğrenme kümesi içerisindeki her bir sınıflandırıcının eğitiminde kullanılacak örneklerin seçiminde iki yaklaşım kullanır. Bunlardan birincisi örneklerin olasılıklarına dayalı olarak eğitim setinin oluşturulmasıdır. İkincisi ise, basit bir biçimde tüm örnekleri ve ağırlıklarının kullanılmasıdır. Bu yöntemin ana düşüncesi her bir örneğin hatasının o örneğin olasılığı ile belirleneceğidir. Adaboost yönteminde başlangıçta her bir örneğin olasılığı  $1/N$  olarak kabul edilir. Daha sonra eğitilen her bir sınıflandırıcının ürettiği sonuçlar dikkate alınarak hatalı sınıflandırılan pikseller ile ilgili olasılıklar tekrar hesaplanır. Eğitimden sonra, her bir sınıflandırıcının ağırlıklı oyu kullanılarak birleşime ait tahminler yapılır. Her bir sınıflandırıcıya ait ağırlıklar, sınıflandırıcıların eğitiminde kullanılan ağırlıklı örneklerden elde edilen doğruluğa göre hesaplanır.

#### **2.8.4.2 Torbalama**

Torbalama algoritması sınıflandırma doğruluğunun artırılması ve aşırı öğrenme olarak bilinen hatanın önlenmesi amacıyla geliştirilen bir toplu öğrenme algoritmasıdır (Breiman, 1996; Tso ve Mather, 2009). Torbalama algoritması temel sınıflandırıcı olarak genelde karar ağaçlarını kullanmaktadır. Torbalama yönteminde, hızlandırma yönteminde olduğu gibi eğitim setinin yeniden örneklenmesinde bir önceki sınıflandırıcının performansı dikkate alınmamaktadır. Bu yöntemde her bir sınıflandırıcının kullandığı eğitim seti rastgele örnekleme prensibinden hareketle elde edilir.  $N$  şeklinde tanımlanan bir veri seti için, torbalama algoritması her birinin boyutu  $n$  ( $n < N$ ) olacak şekilde orijinal veri seti içerisinde rastgele örnekler seçerek bir dizi yeni eğitim seti oluşturur. Ayrıca oluşturulan veri setleri  $M$  sayıda özelliği (spektral bandı) içermektedir. Rastgele örnekleme yapıldığından yeni oluşturulacak eğitim veri setleri içerisinde bazı pikseller tekrarlanırken bazıları ise hiç yer alamayacaktır. Oluşturulan yeni eğitim setleri ile toplu öğrenme kümesindeki tüm sınıflandırıcılar ayrı ayrı eğitilir. Herhangi bir pikselin sınıflandırılmasında, her bir sınıflandırıcı bu pikselin hangi sınıfa ait olduğu ile ilgili bir oy kaydeder. Sonuç olarak piksele ait sınıf etiketi sınıflandırıcılar tarafından en çok oy verilen sınıf olarak tespit edilir (Breiman, 1996; Pal, 2008, Çölkesen, 2009, Kavzoglu ve Colkesen, 2013).

### 2.8.4.3 Çoklu hızlandırma

Çoklu hızlandırma algoritması Adaboost ve torbalama algoritmalarının toplu öğrenme işleminin gerçekleştirilmesinde kullandıkları esasların bir araya getirilmesi olarak tanımlanmaktadır (Webb, 2000). Bu açıdan ele alındığında çoklu hızlandırma algoritması, hızlandırma algoritmasının torbalama algoritmasının özelliklerini de içerecek şekilde yeniden düzenlenmiş hali olarak da tanımlanabilmektedir (Wang ve Hunter, 2010). Çoklu hızlandırma yöntemi hızlandırma algoritması gibi çalışır, aradaki fark belirli sayıda iterasyondan sonra piksellere ait ağırlıklar rastgele atanır (Rodriguez ve diğ, 2010). Orijinal eğitim veri seti içerisinde belirli sayıda rastgele ağırlıklandırılmış yeni eğitim verilerinin oluşturulmasında Poisson dağılımı esas alınmaktadır.


### 2.8.4.4 Rastgele orman algoritması

Popüler toplu öğrenme algoritması olarak bilinen rastgele orman (RO) algoritması temel sınıflandırıcı olarak karar ağaçlarını kullanmaktadır. Temelde bir çeşit karar ağacı algoritması olan RO algoritması eğitim aşamasında birden çok karar ağacını kullanmakta ve bu yapıyla karar ağacı ormanı olarak tanımlanabilmektedir (Breiman, 2001). Şekil 2.16'da temel çalışma prensibi gösterilen RO algoritması, ormandaki her bir karar ağacının eğitimi için orijinal eğitim veri seti içerisinde rastgele alt kümeler oluşturulur. Söz konusu alt kümelerin  $2/3$ 'ü karar ağacı yapısını oluşturmak için kullanılırken, diğer kısmı ağaç yapısının geçerliliğini test etmek için kullanılır. Ormandaki her bir karar ağacı sınıflandırma sonucu bir oy alır ve orman içerisindeki tüm ağaçlardan en çok oy alan (en düşük hata oranına sahip) belirlenerek sınıflandırmaya esas ağaç yapısı tespit edilir. Sınıf etiketi bilinmeyen herhangi bir örnek (piksel), tüm ağaç tahminlerinde en fazla oy alan sınıfa atanması suretiyle sınıflandırılır.

Rastgele orman sınıflandırıcısı karar ağacı oluşumunda dallanma kriterlerinin belirlenmesinde başka bir ifadeyle dallanma için özniteliklerin seçiminde Gini indeksi yöntemini kullanır. Rastgele orman sınıflandırıcısı için kullanıcı tarafından belirlenen iki temel parametre mevcuttur. Bunlardan ilki ağaç yapısının oluşturulması için her bir düğümde kullanılacak örneklerin sayısı ve oluşturulacak ağaç sayısıdır. Her bir düğümde en iyi dallanma için sadece seçilen özellikler araştırılır. Bu nedenle rastgele orman sınıflandırıcısı kullanıcı tarafından belirlenen



ve oluşturulacak ağaç sayısını ifade  $n$  ağaçtan oluşacaktır. Yeni bir veri setinin sınıflandırılmasında, veri seti bu  $n$  sayıda ağacın her birinden geçirilir. Rastgele orman sınıflandırıcısı bu  $n$  sayıda ağaçtan elde edilen  $n$  sayıda oy arasından en fazla oya sahip olan sınıfı seçer ve bu şekilde yeni veri setine ait sınıf etiketini belirler (Pal, 2005, Kavzoglu ve Colkesen, 2013).




Şekil 2.16 : Rastgele orman algoritmasının temel çalışma prensibi.

#### 2.8.4.5 Rotasyon orman algoritması

Son yıllarda literatürde kullanılmaya başlanan yeni nesil topluluk öğrenme algoritması olarak ortaya koyulan rotasyon orman (RotOR) algoritması, bir özellik çıkarma tekniği (temel bileşenler analizi) kullanarak sınıflandırıcı topluluğunun oluşturmasını esasına dayanmaktadır (Rodriguez ve diğ., 2006; Kavzoglu ve Colkesen, 2013; Xia ve diğ., 2014, Çölkesen ve diğ., 2014). RotOR algoritmasının temel çalışma prensibi rastgele orman algoritmasına benzer şekilde olup birden fazla

ağaç kullanılmaktadır. Ancak ormandaki her bir karar ağacının eğitiminde kullanılacak veri seti temel bileşen analizi yardımıyla belirlenmektedir (Şekil 2.17). RotOR algoritması ile ormandaki karar ağaçlarının eğitimi aşamasında eğitim veri seti rastgele alt kümelerle bölünür ve her bir alt küme için temel bileşenler analizi uygulanarak özellik çıkarımı gerçekleştirilir. Özellik çıkarımı neticesinde ayırt ediciliği en yüksek olan özellikler (bantlar) belirlenmektedir. Veri setindeki değişkenlik bilgisini korumak için tüm bileşenler dikkate alınır. Özellik çıkarımı ile sınıflandırıcı kümesindeki her bir sınıflandırıcı için çeşitlilik korunmuş olur.



Şekil 2.17 : Rotasyon orman algoritmasının temel çalışma prensibi.

RotOR algoritmasının temel çalışma prensibi aşağıda verilmiştir  $X$ 'in eğitim veri setini,  $Y$  'nin veri setindeki sınıf etiketlerini,  $F$  de özellik (bant) sayısını gösterdiği

göz önüne alınsın. Eğitim veri setinin  $N$  sayıda pikselden oluştuğu ve  $n$  sayıda arazi örtüsü/kullanım sınıfı olduğu düşünülürse, eğitim veri seti ( $X$ ),  $N \times n$  boyutunda bir matris formundadır. Sınıf etiketlerini ifade eden  $Y$  vektörünün  $[y_1, \dots, y_n]$  şeklinde olduğu düşünölsün. RotOR algoritmasının çalışma prensibine uygun olarak, veri setinin yaklaşık olarak aynı boyutta  $K$  sayıda alt kümeye ayrıldığı, rotasyon ormanda  $D_1, \dots, D_L$  şeklinde gösterilen  $L$  sayıda karar ağacının olduğu göz önüne alınsın. Bu durumda rotasyon ormanındaki her bir karar ağacı  $D_i$  için eğitim veri seti sırasıyla aşağıdaki işlem adımları ile belirlenir:

1. Adım:  $F$  rastgele şekilde  $K$  sayıda bağımsız altkümeye bölünür. Her bir bağımsız alt küme  $M = n/K$  sayıda özelliği (bandı) içermelidir.
2. Adım:  $F_{ij}$  'nin  $D_i$  sınıflandırıcısının eğitiminde kullanılan  $j$  sayıda özelliği içeren alt kümesi ve  $X_{ij}$  'nin  $X$  veri setinde  $F_{ij}$  deki özellikleri içeren veri seti olduğu düşünölsün. Bu durumda yeni bir eğitim veri seti *bootstrap* yaklaşımı ile veri setinin %75 eğitim %25 test veri seti olarak belirlenir. Daha sonra yeni oluşturulan veri setine temel bileşen dönüşümü uygulanarak kovaryans matrisi  $C_{ij}$  hesaplanır.
3. Adım: Hesaplanan kovaryans değerleri kullanılarak (2.21)'deki  $R_i$  dönüşüm matrisi oluşturulur.

$$R_i = \begin{bmatrix} a_{i1}^{(1)}, \dots, a_{i1}^{(M_1)} & \{0\} & \dots & \{0\} \\ \{0\} & a_{i2}^{(1)}, \dots, a_{i2}^{(M_2)} & \dots & \{0\} \\ \dots & \dots & \dots & \dots \\ \{0\} & \{0\} & \dots & a_{iK}^{(1)}, \dots, a_{iK}^{(M_K)} \end{bmatrix} \quad (2.21)$$

$R_i$  matrisinin her bir sütunu orijinal özellik (bant) dizilimine göre yeniden düzenlenir ve yeniden düzenlenen rotasyon matrisi  $R_i^a$  elde edilir. Sonuç olarak  $D_i$  sınıflandırıcının eğitiminde kullanılacak dönöştürölmüş veri seti  $XR_i^a$  olacaktır. Bu işlem adımları rotasyon ormanındaki tüm sınıflandırıcılar için tekrar edilir. Dönöştürölmüş veri setleri kullanılarak ormandaki her bir karar ağacına ait sınıflandırma sonucu bir oy alır. Sınıf etiketi bilinmeyen herhangi bir örnek (piksel), tüm ağaç tahminlerinde en fazla oy alan sınıfa atanması suretiyle sınıflandırılır.

## 2.9 Uzaktan Algılamada Özellik Seçimi


Uzaktan algılamada sınıflandırma problemine esas veri seti olarak yüzlerce spektral banda sahip hiperspektral görüntüler kullanılabileceği gibi birden çok görüntünün birleştirilmesiyle veya optik görüntülerle birlikte yardımcı veri setlerinin bir arada değerlendirildiği yüksek boyutlu veri setlerinin kullanımı söz konusudur. Özellikle hiperspektral görüntüler arazi örtüsü tiplerine ilişkin yoğun spektral veri içerdiğinden multispektral verilere göre benzer spektral özelliklerdeki verilerin ayırt edilmesi noktasında daha etkilidir (Landgrebe, 2003). Algılama yapılan bant sayısındaki artış yeryüzü objelerine ilişkin detaylı bilgiler sunmasına karşın, karmaşık ve yoğun miktarda bilgi içeren veri setlerinin analizi ve işlenmesi problemini ortaya çıkıştır.

Teorik olarak sınıflandırma işleminde spektral çözünürlük veya kullanılan bant sayısı arttıkça sınıflandırmaya esas piksellerin birbirinden daha kolay ayırt edilebileceği öngörülmektedir. Ancak pratik deneyimler bu durumun her zaman geçerli olmadığını göstermektedir (Yang ve Li, 2012). Bunun temel nedeni yüksek spektral çözünürlüğe sahip veri setlerinin bir biri ile korelasyonlu, gürültülü, tekrarlı ve gereksiz bilgiler içeren özelliklere (bantlara) sahip olmasıdır. Boyutsallık problemi (Bellman, 1961) veya Hughes fenomeni (Hughes, 1968) veri boyutunun artmasıyla ortaya çıkan önemli bir problem olarak bilinmektedir. Boyutsallık probleminin uzaktan algılamada görüntü işleme uygulamalarını önemli derecede etkileyen iki temel sonucu vardır. Bunlardan ilki kullanılan bant sayısı arttıkça sınıflandırma probleminin çözümü için daha fazla örnek pikselin kullanımına ihtiyaç duyulmasıdır. İkincisi ise sınıflandırmada kullanılacak modelin karmaşık hale gelerek sınıflandırma sonucunda hatalı piksellerin ortaya çıkmasına ve sınıflandırma doğruluğunun azalmasına neden olmasıdır (Camps-Valls ve diğ., 2011).

Sınıflandırma modelinin karmaşıklığı ve mevcut örnek sayısı arasındaki yakın ilişki nedeniyle sınıflandırma öncesinde yüksek boyutlu veri seti boyutunun azaltılması önemli bir ihtiyaçtır. Bu nedenle söz konusu spektral bantların tamamının bir sınıflandırma probleminin çözümünde kullanılması yerine görüntü üzerindeki piksellerin birbirinden ayırt edilebilmesi için faydalı bilgiler sağlayan, düşük korelasyonlu spektral bantların seçilmesi gerekmektedir. Gereksiz veya tekrarlı bilgiler içeren gürültü oranı yüksek bantların elenerek faydalı bilgiler taşıyan bantların seçilmesi yoluyla gereksiz bellek ihtiyacının önüne geçilerek sınıflandırma

işleminde kullanılan algoritmaların kompleks yapısı sadeleştirilebilmektedir. Bu sayede algoritmaların sınıflandırma probleminin çözümündeki etkinliği ve hesaplama hızı artmakta dolayısıyla yüksek sınıflandırma doğruluklarına ulaşabilmektedir (Camps-Valls ve diğ, 2011). Bu hususta cevap aranan soru, bilgi kaybı olmadan ve sınıflandırma doğruluğunu düşürmeden bant sayısının nasıl azaltılabileceğidir (Li ve diğ, 2011). Yüksek boyutlu veri setinin boyutunun azaltılması ve bant seçiminin gerçekleştirilmesinde özellik seçimi ve özellik çıkarımı olarak tanımlanan iki farklı yaklaşım kullanılmaktadır. Özellik seçiminde sınıflandırma işlemine katkısı olmayan bantlar belirlenerek ihmal edilirken, özellik çıkarımında yararlı bilgileri koruyacak şekilde özellik uzayının daha düşük boyutlu bir uzaya dönüştürülmesi işlemi gerçekleştirilir. Hiperspektral görüntülerin sahip olduğu her bir spektral bant kendi başına bir görüntü olduğundan, yüksek boyutlu veri setinin doğrusal veya doğrusal olmayan dönüşümlerini esas alan özellik çıkarımı yaklaşımı görüntünün orijinal fiziksel halini koruyamamaktadır. Bu nedenle özellik çıkarımı hiperspektral görüntülerin boyut azaltımı için uygun bir yaklaşım değildir (Li ve diğ, 2011).

Özellik seçimi orijinal özellikleri (bantları) içeren veri seti içerisinde belirli algoritmalar veya ölçütler kullanılarak daha az sayıda özelliği içeren bir alt küme elde etme işlemidir. Bu nedenle özellik seçimi alt küme seçimi ya da değişken seçimi olarak da tanımlanabilmektedir. Özellik seçimi ile boyutu azaltılan veri seti benzer karakteristikteki pikselleri birbirinden ayırt edebilmesine imkan sağlayan bantları içermelidir. Şekil 2.18'den de görüleceği üzere özellik seçimi değerlendirme işlemi iki temel aşamada gerçekleştirilmektedir. İlk aşamada özellik seçimi algoritmaları tarafından dikkate alınan değerlendirme ölçütleri ve arama stratejilerine dayalı olarak orijinal eğitim veri seti içerisinde aday alt özellik kümeleri oluşturulur. İkinci aşamada ise değerlendirme ölçütleri ile belirlenen sonuç alt kümeyi oluşturan özellikler dikkate alınarak seçilen sınıflandırma algoritmasının performansı değerlendirilir (Wu ve diğ, 2013). Şekilden de görüleceği üzere özellik seçiminin temel yapı taşı olarak ifade edilebilecek dört önemli bileşeni mevcuttur. Bunlar, kullanılacak veri seti, özellik altkümelerinin oluşumunda kullanılacak algoritmalar, alt kümeleri değerlendirme ölçütleri ve doğruluk analizidir.




**Şekil 2.18 :** Özellik seçimi ve değerlendirilmesinde temel iş akışı.

Özellik seçimi başta uzaktan algılama olmak üzere, veri madenciliği, metin ve görüntü işleme uygulamalarında yaygın kullanıma sahip bir tekniktir (Baccianella ve diğ, 2014; Fassnacht ve diğ, 2014; Mwangi ve diğ, 2014). Özellik seçiminin temel amacı en önemli bantların korunarak veri seti boyutunun azaltılmasıdır. Bu amaca yönelik olarak literatürde birçok metot önerilmiştir (Saeys ve diğ, 2007; Kumar ve Minz, 2014). Özellik seçiminde filtreleme (Blum ve Langey, 1997) ve sarmalama (wrappers) (Kohavi ve John, 1997) olarak bilinen iki temel yaklaşım kullanılmaktadır.


Filtreleme metotları, özellik seçiminde bantların kalitesinin belirlenmesinde dolaylı ölçütler kullanmaktadır. Bu ölçütlere örnek olarak bantlar arasındaki korelasyonun değerlendirilmesi veya veri setindeki her bir özelliğin (bandın) sınıflandırma doğruluğuna etkisinin değerlendirilmesi gösterilebilir. Filtre yönteminde özellik seçiminde kullanılan algoritmanın performansının optimize edilmesinden ziyade bir ölçüt veya değerlendirme fonksiyonunu maksimum yapan alt küme belirlenir (Şekil 2.19). Filtre yönteminde, sınıflandırma sonucunda ulaşmak istenen hedef sınıflar ve seçilecek bantlar arasında güçlü bir ilişki olduğu göz önüne alınarak sınıfları birbirinden en iyi şekilde ayırt edebilecek özelliklerin seçilmesi söz konusudur. Bu nedenle filtre yönteminde belirli bir sınıflandırma problemin çözümünde değerlendirmeye alınan her bir özelliğin problem çözümündeki katkısı veya önem derecesi belirlenir ve sonuca katkısı olmayan özellikler veri seti içerisinden çıkarılarak boyut azaltılır. Sadece eğitim veri seti değerlendirmeye alındığından

filtreleme algoritmalarında hesaplama karmaşıklığı daha azdır. Buna karşın hiperspektral görüntülerde olduğu gibi yüksek korelasyona sahip veri setleri için bu tip özellik seçimi algoritmaları başarısız olabilmekte, sadece her bir bandın puanlanması amacıyla kullanılabilir (Li ve diğ, 2011).



**Şekil 2.19 :** Sarmalama çalışma prensibi.

Sarmalama yönteminde özellik seçiminde kullanılan algoritmanın performansının optimize edilmesi hedeflenmektedir. Bu amaçla seçilen özellikler ile sınıflandırıcının sınıflandırma performansı değerlendirilir. Diğer bir ifadeyle orijinal veri seti içerisinde seçilen her bir alt küme ile sınıflandırma işlemi gerçekleştirilir ve en iyi çözme ulaşılan altküme belirlenir (Şekil 2.20). Yüksek boyutlu veri seti için seçilecek olası alt küme sayısı üstel bir fonksiyonla hesaplanabileceğinden işlem süresi oldukça uzundur.



**Şekil 2.20 :** Sarmalama algoritmalarının çalışma prensibi.

Sarmalama ve filtreleme yöntemlerinin her ikisi de deneysel yöntemler olmasına karşın, sarmala yöntemi özellik seçimi için uzun işlem süresi gerektirmekteyken,

filtreleme yönteminde işlem süresi kısa dolayısıyla özellik seçimi hızlıdır. Filtreleme metotlarının seçtiği bantların oluşturduğu altkümenin en iyi altküme olmayabileceği veya sarmala metotlarının ise makine öğrenme algoritmalarının tekrarlı bir şekilde eğitimini gerektirdiğinden yoğun hesaplamalar gerektirmesi yöntemlerin dezavantajları arasındadır.

### 2.9.1 Ki-kare testi

Ki-kare özellik seçimi algoritması ki-kare ( $\chi^2$ ) istatistiğine dayanan ve her bir özelliği sınıf etiketlerine göre birbirinden bağımsız olarak değerlendiren bir algoritmadır (Plackett, 1983; Mingers, 1989). Ki-kare testi bir banttaki sınıflara ait değerlerin dağılımını inceler. Hesaplanan istatistik değer arttıkça değerlendirmeye alınan özelliğin sınıflarla ilgili daha faydalı bilgi içerdiği anlamına gelmektedir. Sıfır hipotezi korelasyon olmadığı yönündedir. Diğer bir ifadeyle belirli bir banttaki değer sınıflardan sadece birine aittir. Söz konusu hipotez göz önüne alınarak,  $\chi^2$  istatistiği gerçek değer beklenen değerden ne kadar uzakta olduğunu ölçer. İstatistik değeri,

$$\chi^2 = \sum_{i=1}^r \sum_{j=1}^{n_c} \frac{(O_{i,j} - E_{i,j})^2}{E_{i,j}} \quad (2.22)$$

şeklinde hesaplanır. Eşitlikte  $r$  bir banttaki (özellikteki) farklı değerlerin sayısını,  $n_c$  sınıf sayısını,  $O_{i,j}$ ;  $j$  sınıfı içindeki  $i$  değerine sahip piksellerin gözlenen sayısını ve  $E_{i,j}$ ;  $j$  sınıfı ve  $i$  değerine sahip örneklerin beklenen sayısını ifade etmektedir. Hesaplanan  $\chi^2$  değeri ne kadar yüksek olursa, pikseller değerlerinin ve sınıfların dağılımının o kadar bağımlı olduğu, diğer bir ifadeyle değerlendirmeye alınan özelliğin sınıflar ile ilişkili olduğu ifade edilir.

### 2.9.2 Fisher testi

Fisher testi özellik seçimi için kullanılan en basit filtre algoritmalarından birisidir (Duda ve Hart, 1973; Xie ve Wang, 2011). İki sınıfı içeren veri seti ele alındığında, veri setini oluşturan her bir  $t$  özelliği için (2.23) yardımıyla bir skor hesaplanır. Özellik seçimi probleminin çözümünde temel düşünce veri seti içerisindeki herhangi bir bandın sınıflandırmaya esas iki sınıfı birbirinden ne kadar ayırabildiğinin belirlenmesidir.



$$F_t = \frac{(\mu_1 - \mu_2)}{\sigma_1^2 + \sigma_2^2} \quad (2.23)$$

Eşitlikte  $\mu_1$  1. sınıfa ait  $t$  değerlerinin ortalamasını;  $\mu_2$  2. sınıfa ait  $t$  değerlerinin ortalamasını;  $\sigma_1$  1. sınıfın standart sapmasını ve  $\sigma_2$  2. sınıfın standart sapmasını göstermektedir. Uzaktan algılama problemlerinde de olduğu gibi ikiden fazla sınıfın mevcut olduğu problemlerin çözümünde (2.23)'ün genişletilmiş hali göz önüne alınır (2.24).

$$F_t = \frac{\left(\mu_1 - \sum_{i=2}^M \mu_i\right)^2 + \dots + \left(\mu_j - \sum_{i=1, i \neq j}^M \mu_i\right)^2 + \dots + \left(\mu_M - \sum_{i=1}^{M-1} \mu_i\right)^2}{\sum_{i=1}^M \sigma_i^2} \quad (2.24)$$

Eşitlikte  $M$  sınıf sayısını göstermektedir. Fisher testi aracılığıyla veri seti içerisindeki tüm bantlar için bir sıralama hesaplanır. Algoritma bantların birbirinden bağımsız olduğu kabulünü yapmaktadır. Bu açıdan ele alındığında her bir  $F_t$  katsayısı tek bir bant ile ilgili bilgiyi dikkate almakta veri seti içerisindeki diğer bantlar arasındaki karşılıklı bilgiyi değerlendirmeye almamaktadır.

### 2.9.3 Bilgi kazancı

Bilgi kazancı makine öğrenmesi ve bilgi teorisi alanlarında yaygın olarak kullanılan bir ölçüttür (Quinlan, 1993). Bilgi kazancı (InfG) entropi kavramına dayalı çalışmaktadır. Entropi bir sistemdeki belirsizliğin ölçütü olarak tanımlanmaktadır.  $X$  özelliği (bandı) ve  $Y$  sınıfı için bilgi kazancı hesaplandığı göz önüne alınırsa, bilgi kazancı  $X$  bilindiğinde  $Y$  değerindeki belirsizliğin azaltılmasıdır.  $Y$  değeri kendisine ait entropisi ile ölçülür ( $H(Y)$ ). Belirli bir  $X$  özelliği için  $Y$  ile ilgili belirsizlik  $Y$ 'nin  $X$ 'e bağlı şartlı olasılığı olarak ifade edilir ( $H(Y/X)$ ). InfoG algoritması ile özellik seçiminde temel olarak, bir özellik kullanarak bir sınıfla ilgili ne kadar çok bilgi edinildiği araştırılır. Her bir özellik için bu işlem tekrar edilerek tüm özelliklere ait puanlamalar yapılır. En yüksek puanı alan bant sınıflarla ilgili en fazla bilgiyi içeren bant olma özelliğine sahiptir.  $X$  bandına ait bilgi kazancı (2.25) yardımıyla hesaplanmaktadır.

$$InfG(X) = H(Y) - H(Y/X) \quad (2.25)$$

Eşitlikte  $Y=\{y_1, \dots, y_k\}$  ve  $X=\{x_1, \dots, x_l\}$  olarak göz önüne alınırsa  $Y$ 'nin entropisi,

$$H(Y) = -\sum_{i=1}^{i=k} P(Y = y_i) \log_2 P(Y = y_i) \quad (2.26)$$

şeklinde hesaplanır.  $Y$ 'nin  $X$ 'e göre şartlı entropisi,

$$H(Y/X) = -\sum_{j=1}^l P(X = x_j) H(Y/X = x_j) \quad (2.27)$$

şeklinde dir. Sonuç olarak bilgi kazancı ile ilgili genel formül (2.28) ile ifade edilir.

$$I(Y; X) = H(X) + H(Y) - H(X, Y) \quad (2.28)$$

Bu formülde  $Y$  sınıf etiketini,  $H(Y)$   $Y$ 'nin entropisi,  $H(Y/X)$   $X$ 'e dayalı  $Y$ 'nin şartlı entropisini göstermektedir. Bir özelliğin farklılığı göz önüne alınan özellik içerisindeki sınıfa ait hesaplanan entropideki artışa göre belirlenir.

#### 2.9.4 Kazanç oranı

Kazanç oranı (GainR) bilgi kazancı yaklaşımının yeniden düzenlenmesi sonucunda elde edilen bir ölçüttür (Quinlan, 1993). InfoG yaklaşımında bilgi içeriği yüksek değerler sahipken, GainR yaklaşımında bir özelliğe ait bilgi maksimum tutulurken özelliğe karşılık gelen değer minimum hale getirilir. (2.29)'da da gösterildiği üzere bir özelliğe ( $X$ ) ait kazanç oranı, o özelliğe ait bilgi kazancı değerinin, kendi öz değerine bölümü ile elde edilir.

$$GainR(X) = InfoG(X) / IV(X) \quad (2.29)$$

Bu eşitlikte bilgi kazancının öz değeri  $IV(X) = -\sum_{i=1}^r (|X_i|/N) \log(|X_i|/N)$  şeklinde hesaplanır. Bu eşitlikte  $|X_i|$ ,  $X$  özelliği  $X_i$  değerini aldığı anda içerisinde bulunan örnek (piksel) sayısını;  $r$ ,  $X$  özelliğindeki farklı değerlerin sayısını ve  $N$  veri setindeki toplam piksel sayısını göstermektedir.

#### 2.9.5 Naive bayes

Olasılık teoremine dayalı Naive Bayes sınıflandırıcısı matematiksel olarak basit ve literatürde sık kullanılan kontrollü öğrenme algoritmasıdır (John ve Langley, 1995;

Domingos ve Pazzani, 1997). Algoritma sahip olduğu basit matematiksel yapısına rağmen karmaşık sınıflandırma problemlerin çözümünde iyi performans sergilemektedir. Ayrıca bu modelin önemli bir özelliği ise kullanılan veri setleri içerisindeki az miktardaki gürültünün model sonucu üzerindeki etkilerinin az olmasıdır. Naïve Bayes sınıflandırıcısı Bayes teoremine dayalıdır ve aşağıdaki temel eşitlikle ifade edilebilir (Rish, 2001).  $X = [x_1, \dots, x_n]$  sınıf etiketi belirli olmayan girdi verisini,  $m$ , sınıf sayısını,  $C = [C_1, \dots, C_m]$ , sınıf değerleri olduğu düşünüldüğünde sınıfı etiketi belirlenecek olan piksele ait olasılık (2.30) ile hesaplanır.

$$P(C_i|X) = \frac{P(X/C_i)P(C_i)}{P(X)} \quad (2.30)$$

Hesaplamalardaki işlem yükünü azaltmak için örneğe ait  $x_i$  değerlerinin birbirinden bağımsız olduğu kabul edilerek temel formül (2.31) şeklinde sadeleştirilir.

$$P(X|C_i) = \prod_{k=1}^n P(x_k|C_i) \quad (2.31)$$

### 2.9.6 Pearson's korelasyonu

İki özellik arasındaki Pearson's korelasyon katsayısı söz konusu iki özelliğin kovaryanslarının standart sapmalarına oranı ile hesaplanmaktadır (Biesiada ve Duch, 2007).  $X$  değerlerine sahip  $X$  özelliği ve  $y$  değerlerine sahip  $Y$  sınıfları rastgele değişkenler olarak tanımlandığı düşünüldüğünde korelasyon katsayısı (2.32) yardımıyla hesaplanır.

$$\rho(X,Y) = \frac{E(XY) - E(X)E(Y)}{\sqrt{\sigma^2(X)\sigma^2(Y)}} = \frac{\sum_i (x_i - \bar{x}_i) \sum_i (y_i - \bar{y}_i)}{\sqrt{\sum_i (x_i - \bar{x}_i)^2 \sum_i (y_i - \bar{y}_i)^2}} \quad (2.32)$$

Korelasyon katsayısı bir özelliğin diğer özelliğe ne kadar yakın olduğu hakkında bilgi vermektedir. Korelasyon iki rastlantısal değişken arasındaki doğrusal ilişki gücünün ölçüsüdür ve bir özellikteki değişimlerin diğer özelliklerdeki değişimlerle ne kadar ilişkili olduğunun tahmin edilmesinde kullanılır.

Hesaplanan Pearson korelasyon katsayıları  $[-1,1]$  aralığında değerler almaktadır. Örneğin (2.32)'den hesaplanan istatistik değer -1 veya 1'e eşitse iki özellik arasında

mükemmel bir doğrusal ilişki olduğunu göstermektedir. İstatistik değer 0'a eşitse iki özellik arasında ilişki olmadığını göstermektedir. Hesaplanan değer  $0 < \rho(X,Y) < 1$  veya  $0 > \rho(X,Y) > -1$  aralığında değerler aldığında, iki özellik arasında pozitif veya negatif ilişki olduğu söylenebilir.  $\rho(X,Y)$  büyük değerler aldıkça ilişkinin gücü artmaktadır.

### 2.9.7 One-R

Bu özellik seçimi algoritması veri setindeki her bir özelliği OneR sınıflandırıcısı kullanarak değerlendirir. OneR sınıflandırıcısı eğitim seti kullanılarak elde edilen hata oranlarını dikkate alarak özellikleri sıralar. Algoritma tüm sayısal değerli özellikleri sürekli özellikler olarak kabul eder ve belirli bir aralıktaki değerleri birkaç değer aralığına bölmek için basit bir yöntem kullanır (Holte, 1993).

OneR algoritması örnek veri kümesindeki özelliklere dayalı olarak sınıflandırma kuralları oluşturur. Eğitim veri setindeki her bir özelliğe dayalı olarak bir kural belirlenir ve bir sınıfa ait verilerin söz konusu özellikte ne kadar doğru tahmin edildiği araştırılır. OneR algoritmasının temel çalışma prensibi Şekil 2.21'de bir örnek üzerinde gösterilmiştir. Şekil 2.21a'da Landsat TM uydu görüntüsüne ait kırmızı bant kullanılarak iğne ve geniş yapraklı sınıflara ait toplam 10 pikselin OneR ile sınıflandırılması problemi ele alınmıştır. Şekilden de görüleceği üzere kırmızı banttaki yansıma değeri 170-180 olan piksellerin gerçekte iğne yapraklı ağaç sınıfını (A), 240-242 olan piksellerin ise geniş yapraklı ağaç sınıfını (B) temsil ettiği bilinmektedir. OneR algoritması ilk olarak sınıflar ve piksel değerleri arasındaki niceliksel ilişkiyi inceleyerek Şekil 2.21'deki hata matrisi üretilir. Hata matrisi yardımıyla değerlendirmeye alınan bandın toplam hatası hesaplanır. Bu şekilde veri seti içerisindeki tüm bantlar değerlendirmeye alınarak hesaplanan hata oranı en az olandan başlanarak tüm bantlar sıralanır. Diğer bir ifadeyle hata oranı en az olan bant sınıflar arasındaki ayırmada en etkili olan özellik olarak seçilir.

| Kırmızı bant<br>(piksel değeri) | Tahmin edilen<br>sınıf etiketi | Bilinen sınıf<br>etiketi |
|---------------------------------|--------------------------------|--------------------------|
| 180                             | A                              | A                        |
| 240                             | B                              | B                        |
| 242                             | B                              | B                        |
| 176                             | A                              | A                        |
| 170                             | A                              | A                        |
| 241                             | A                              | B                        |
| 179                             | B                              | A                        |
| 172                             | A                              | A                        |
| 175                             | B                              | A                        |
| 245                             | A                              | B                        |

(a)

| Sınıflar          | A | B |
|-------------------|---|---|
| A                 | 4 | 2 |
| B                 | 2 | 2 |
| Toplam hata : 2/5 |   |   |

(b)

**Şekil 2.21 :** OneR algoritmasının temel çalışma prensibi.

### 2.9.8 Olasılıksal anlamlılık

Olasılıksal anlamlılık algoritması ile veri seti içerisindeki bir özelliğin istatistiksel anlamlılığının ölçülmesinde temel alınan hipotez, anlamlı bir özelliğin farklı sınıflar için farklı özellikler almasıdır (Ahmad ve Dey, 2005). Algoritma iki yönlü bir fonksiyon olarak bilinen olasılıksal farkın hesaplanması yoluyla veri seti içerisindeki her bir özelliğin olasılık değerini belirler. Diğer bir ifadeyle özellik ve hedef sınıflar arasındaki ilişki değerlendirmeye alınmaktadır. Bu açıdan, iyi özellik hedef sınıflar ile anlamlı bir ilişkiye sahip olmalıdır (Zhou ve Dillon, 1988; Liu ve Setiono, 1996).

### 2.9.9 ReliefF

ReliefF iki sınıflı sınıflandırma problemleri için kullanılan orijinal Relief algoritmasına dayalı bir özellik seçim algoritmasıdır (Witten ve diğ, 2011). Relief algoritmasının temel çalışma prensibi birbirine yakın pikselleri ayırt edebilme kabiliyetine göre özelliklerin sıralanması esasına dayanmaktadır. Diğer bir ifadeyle algoritma, bir bandın benzer pikselleri ayırt edebilme kabiliyetinin ölçülmesi esasına dayanmaktadır. Çok sınıflı ve kayıp değerlerin olduğu veri setleri için Relief algoritması genelleştirilerek ReliefF şeklinde uygulamalarda kullanılmaktadır (Kononenko, 1994; Robnik-Sikonja ve Kononenko, 2003; Wu ve diğ, 2013).

ReliefF algoritması ile özellik seçiminde kullanılan fonksiyona en uygun olan özellikler seçilir (Kira ve Rendell, 1992). Algoritmanın temel çalışma prensibi  $k$ -en yakın komşuluk algoritmasına benzer bir şekilde olup belirli bir mesafeye yakın uzaklıkların aynı sınıfa ait olma olasılığı yüksektir prensibi göz önüne alınmaktadır. ReliefF algoritması ile bir özelliğin önem derecesi (2.33) yardımıyla hesaplanır.

$$\left( \sum_{j=1}^m -diff(x_{ij}, near\_hit_{ij}) + diff(x_{ij}, near\_miss_{ij}) \right) / m \quad (2.33)$$

Eşitlikte  $m$  örnek boyutunu (eğitim verisinden rastgele seçilen bir alt küme),  $diff(x_{ij}, near\_hit_{ij})$  rastgele seçilmiş  $j$  mesafesi içindeki  $i$  özniteliğinin değeri ile aynı sınıfa sahip en yakın eğitim örneğindeki  $i$  özniteliğinin ( $near\_hit_{ij}$ ) değeri arasındaki farklılığı göstermektedir. Paralel olarak, ( $near\_miss_{ij}$ ) değerlerinin farklı olmaları beklenirken,  $x_{ij}$  ve  $near\_hit_{ij}$  değerlerinin çok yakın olması beklenir. Eğer bir öznitelik yararlı değilse, her iki farklılığın da hemen hemen aynı dağılımı almaları beklenir.

### 2.9.10 Rastgele orman

Rastgele orman tabanlı yaklaşım filtre ve sarmal metotların birleşimi olarak ifade edilen gömülü (hibrit) özellik seçimi algoritmasıdır. Rastgele orman birçok karar ağacı sınıflandırıcının bir arada bulunduğu bir yapıyı ifade etmektedir (Breiman, 2001). Bu yapıda orman içerisindeki her bir karar ağacı eğitim veri seti içerisinde rastgele seçilen örnek kümeleri ile eğitilir. Rastgele seçilen örnek kümeleri içerisinde verilerin 2/3'ü eğitim, 1/3'ü sınıflandırma modelinin testi için kullanılır. Ormandaki karar ağaçlarının eğitimi sonucunda eğitim veri setleri içerisinde bazı veriler çıkarılır. Daha sonra test veri seti kullanılarak sınıflandırma işlemi sırasında farklı özelliklerin önem derecesi belirlenir. Son olarak bir özelliğin anlamlılık (önemlilik) düzeyinin belirlenmesinde kullanılan  $Z$  değerine bağlı olarak veri seti içerisindeki tüm özellikler önem derecesine göre sıralanır (Breiman, 2001; Pal and Foody, 2010; Löw ve diğ, 2013).

### 2.9.11 Özyinelemeli özellik eleme esasına dayalı destek vektör makineleri

Özyinelemeli özellik eleme esasına dayalı destek vektör makineleri (DVM-ÖÖE) algoritması, destek vektör makinelerini temel sınıflandırıcı olarak kullanan sarmal tabanlı özellik seçimi algoritmasıdır (Guyon ve diğ, 2002; Pal ve Foody, 2010). Algoritma veri seti içerisindeki özelliklerin sınıfları ayırt edebilme kabiliyetine göre sıralanmasında DVM sınıflandırıcısının temel amaç fonksiyonu olan  $(1/2)\|w\|^2$  eşitliğini özellik sıralama kriteri olarak kullanmaktadır. Her bir işlem adımında, ağırlık vektörüne ( $w$ ) ait katsayılar tüm özelliklerin sıralama puanlarının hesaplanmasında kullanılır. Bu açıdan ele alındığında, en küçük sıralama puanına  $((w_i)^2)$  sahip olan özellik elenir. Burada  $w_i$ ,  $i$ . özelliğin ağırlığını göstermektedir. Bu özellik seçimi yaklaşımı bir veri seti içerisindeki özelliklerin önem sırasına göre sıralandırılması işlemlerinin gerçekleştirilmesinde özyinelemeli yaklaşımla anlamsız özelliklerin belirlenmesinde geri yönlü eliminasyon şemasını kullanmaktadır.

### 2.9.12 Simetrik belirsizlik

Korelasyon tabanlı özellik seçimi algoritması olarak bilinen simetrik belirsizlik (SymtUnc) algoritması, “*iyi özellik altkümesi sınıflarla ilgili yüksek korelasyonlu bilgiler içerirken, özelliklerin birbirleriyle korelasyonu yoktur*” hipotezinden yola çıkarak bir özellik altkümesi içerisindeki her bir özelliğin ne kadar faydalı olduğunu değerlendirir (Yu ve Liu, 2003; Biesiada ve Duch, 2007). Farklı özellikler arasındaki ilişkinin derecesini belirleyen simetrik belirsizlik ölçütü olarak entropiden yararlanır. Bu açıdan ele alındığında simetrik belirsizlik, bir sınıf ile bir özellik arasındaki korelasyon ölçüsüdür ve (2.34) yardımıyla hesaplanır.

$$SymtUnc = 2 \times \frac{H(X) + H(Y) - H(X,Y)}{H(X) + H(Y)} \quad (2.34)$$

Bu eşitlikte  $H(X)$  bir özelliğe ait entropiyi gösterirken,  $H(Y)$  bir sınıfa ait entropiyi göstermektedir.  $H(X,Y)$ ,  $X$  ve  $Y$  değerlerinin kombinasyonu için hesaplanan olasılık değeridir. Hesaplanan istatistik 0 ile 1 arasında değerler almaktadır. Hesaplanan değer 1 olduğunda bir değişkenin ( $X$  veya  $Y$ ) diğer değişkeni tamamen tahmin edebildiği, değer 0 olduğunda ise her iki değişkeninin birbirinden tamamen bağımsız olduğu ifade edilebilir.

### 2.9.13 t-test

Hipotez testleri içerisinde en yaygın olarak kullanılan t-testi farklı özellikler içerisinde spesifik bir özelliğin ortalama değerlerine dayanan bir hipotez testidir. t-testi ile iki özelliğe ait sınıf değerlerinin ortalamaları karşılaştırılarak aradaki farkın istatistiksel olarak anlamlılığı araştırılır. Diğer bir ifadeyle iki özelliğin ortalamaları arasında farklılık olup olmadığını inceleyen parametrik bir testtir (Theodoridis ve Koutroumbas, 2009). İki özelliğin birbirinden anlamlı bir şekilde farklılığının araştırılmasında iki örnekli test kullanılmaktadır.

$x_i$  'nin ( $i=1,2,3,...,N_1$ ) belirli bir özellik değerlerini alan  $C_1$  sınıfı içerisinde seçilen rastgele değişkenlerin ortalama değerinin  $M_1$  ve varyansının  $V_1$  olduğu düşünölsün. Aynı şekilde  $C_2$  sınıfı içerisinde seçilen rastgele değişkenlerin ortalama değerinin  $M_2$  ve varyansının  $V_2$  olduğu düşünölsün. Bu durumda t-testi (2.35) yardımıyla hesaplanır.


$$t = \frac{|M_1 - M_2|}{\sqrt{\frac{V_1}{N_1} + \frac{V_2}{N_2}}} \quad (2.35)$$



### 3. ÇALIŞMA ALANI VE VERİ TOPLAMA İŞLEMLERİ

#### 3.1 Çalışma Alanı

Tez kapsamında önerilen yaklaşımın geçerliliğini ve işlerliğini test etmek amacıyla Kocaeli iline bağlı Gebze ilçesinin batı kısmında, İstanbul ili sınırında yer alan ve Gebze Teknik Üniversitesi (GTÜ) Çayırova kampüsünü de kapsayan yaklaşık 220 hektarlık bölge çalışma alanı olarak belirlenmiştir (Şekil 3.1). Çalışma alanı içerisinde yer alan GTÜ kampüsü toplam 140 hektar açık ve kapalı alana sahip olup, birçok geniş ve iğne yapraklı ağaç türünü bünyesinde barındıran 24,5 hektarlık yeşil alanıyla yoğun sanayi bölgesi olarak bilinen ilçede doğal hayatı koruyabilmiş ender örneklerdendir.



Şekil 3.1 : Çalışma alanı haritası, Kocaeli Gebze ilçesi.

### 3.2 Uygulama Konusu ve Amacı

Arazi örtüsü veya arazi kullanımının haritalanması uzaktan algılama teknolojilerinin yaygın olarak kullanıldığı uygulama alanlarının başında gelmektedir. Özellikle son yıllarda algılama teknolojilerinin tasarımında yaşanan gelişmeler neticesinde uydu görüntülerinin sağladığı konumsal ve spektral bilgi içeriği zenginleşerek yeryüzü objelerine ilişkin daha detaylı bilgiler elde edilmesine imkan sağlamıştır. Yüksek konumsal çözünürlüğe sahip görüntüler yeryüzü objelerinin görsel olarak daha kolay yorumlanmasına imkan sağlamaktadır. Buna karşın, yüksek çözünürlüğe sahip görüntüler üzerinden benzer spektral özelliklere sahip görüntü piksellerinin geleneksel görüntü analiz teknikleriyle sınıflandırılması ve doğruluğu yüksek tematik harita üretimi süreci karmaşık bir hal almıştır. Bu nedenle yeni nesil uydu görüntülerinin analizi ve yorumlanması noktasında yeni yaklaşım ve tekniklere ihtiyaç duyulmaktadır.

Tez kapsamında, yüksek çözünürlüklü multispektral uydu görüntüsü üzerinden spektral olarak benzer özelliklere sahip ağaç türlerinin ayırt edilmesi ve görüntü üzerinde karışık pikseller olarak tanımlanan söz konusu objelerin sınıflandırılması probleminin çözümüne yönelik bir yaklaşımın ortaya konulması amaçlanmaktadır. Bu amaç doğrultusunda çalışma alanında spektrometre ölçümleri gerçekleştirilerek benzer spektral özelliklere sahip ağaç türleri için spektral kütüphane oluşturulmuştur. Oluşturulan spektral kütüphane yardımıyla bitki türlerinin spektral özellikleri analiz edilerek türlerin spektral olarak ayırt edilebilirlikleri incelenmiştir. Spektral kütüphane 8 spektral banda sahip yüksek konumsal çözünürlüklü tek uydu olan WorldView-2 uydu görüntüsü ile ilişkilendirilmiş ve sınıflandırma işlemine esas teşkil edecek ağaç türlerine ait örnekleme alanları spektral kütüphane yardımıyla tespit edilmiştir. Çalışma alanında tespit edilen arazi örtüsü/kullanım sınıfları arasındaki spektral ayrımın artırılması amacıyla multispektral uydu görüntüsüne ilave olarak 12 farklı vejetasyon indeksi, çeşitli doku özellikleri ve temel bileşenler analizi ile elde edilen bileşenler hesaplanmış ve yardımcı veri olarak değerlendirmeye alınmıştır. Sınıflandırma işleminin gerçekleştirilmesinde piksel ve obje tabanlı kontrollü sınıflandırma yaklaşımları kullanılarak yüksek çözünürlüklü görüntülerin sınıflandırılması problemindeki etkinlikleri karşılaştırılmalı olarak analiz edilmiştir. Gerek piksel gerekse obje tabanlı yaklaşımla veri setinin sınıflandırılması ve çalışma alanına ait

tematik harita üretilmesinde ileri sınıflandırma algoritmalarından destek vektör makineleri, karar ağaçları, çeşitli toplu öğrenme algoritmaları ve geleneksel sınıflandırma yöntemlerinden en yakın komşuluk algoritması kullanılmıştır. Multispektral görüntü ve yardımcı verilerden oluşan yüksek boyutlu veri seti içerisinde korelasyonu düşük ve faydalı bilgiler içeren bantların belirlenerek boyut indirilmesi amacıyla istatistiksel algoritmaların yanında özyinelemeli özellik eleme esasına dayalı destek vektör makineleri ve rastgele orman gibi ileri özellik seçimi algoritmaları değerlendirilmeye alınmıştır. En uygun veri seti boyutunun tespiti ve sınıflandırmada kullanılan algoritmaların veri seti boyutu artışına göre performanslarının analizi amacıyla özellik seçimi ile belirlenen bant önem sıralamaları dikkate alınarak farklı boyutlarda veri setleri oluşturulmuş ve her bir sınıflandırma algoritmasının söz konusu veri setleri için performansı analiz edilmiştir. Sonuç olarak tez kapsamında ele alınan problemin çözümünde spektrometre ölçümleri ve spektral kütüphanelerin kullanımı, yüksek çözünürlüklü uydu görüntülerinin kullanımı, yardımcı verilerin sınıflandırma doğruluğuna etkileri, özellik seçiminin sınıflandırma doğruluğuna etkisi ve özellik seçiminde kullanılan algoritmaların performans analizi, sınıflandırma yaklaşımları ve sınıflandırma algoritmalarının performanslarının detaylı bir şekilde analiz edilmesi amaçlanmıştır.

### **3.3 WorldView-2 Görüntüsü ve Gerçekleştirilen Ön İşlemler**

Tez kapsamında farklı bitki türlerinin ayırt edilmesinde temel veri olarak kullanılan WorldView-2 uydusu, 2009 yılı Ekim ayında uzaya gönderilmiş olup, dünyanın 8 spektral banda sahip ilk yüksek çözünürlüklü gözlem uydusu olma özelliğine sahiptir. Çizelge 3.1’de teknik özellikleri verilen WorldView-2 (WV-2) uydusu, yeryüzünden 770km yükseklikte konumlandırılmış olup hem 0,50m yersel çözünürlüklü pankromatik hem de 2m yersel çözünürlükte multispektral görüntüleme yapabilmektedir. WV-2 diğer yüksek çözünürlüklü uydularda da mevcut olan ve standart bantlar olarak tanımlanan kırmızı, yeşil, mavi ve yakın kızılötesi (NIR1) bantlarda görüntüleme yapabilmektedir. Bu bantlara ek olarak 400-450nm dalga boyu aralığındaki kıyı, 585-625nm aralığındaki sarı, 705-745nm aralığındaki kırmızı kenar ve 860-1040nm aralığında ikinci bir yakın kızılötesi (NIR2) bantlarda da algılama yapabilmektedir.

**Çizelge 3.1 : WorldView-2 uydusunun teknik özellikleri.**

|                                                                                   |                         |                                                                                                                                                                                                                                            |
|-----------------------------------------------------------------------------------|-------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
|  | Yörünge:                | Yükseklik: 770 kilometre<br>Tip: Güneş senkronizasyonlu<br>Periyod: 100 dakika                                                                                                                                                             |
|                                                                                   | Spektral Çözünürlük:    | Pankromatik: 450 - 800nm<br>Kıyı: 400 - 450nm<br>Mavi: 450 - 510nm<br>Yeşil: 510 - 580nm<br>Sarı: 585 - 625nm<br>Kırmızı: 630 - 690nm<br>Kırmızı kenar: 705 - 745nm<br>Yakın kızılötesi-1: 770 - 895nm<br>Yakın kızılötesi-2: 860 - 1040nm |
|                                                                                   | Yersel Çözünürlük:      | Pankromatik: 0,5 m<br>Multispektral: 2 m                                                                                                                                                                                                   |
|                                                                                   | Radyometrik Çözünürlük: | 11bit                                                                                                                                                                                                                                      |

Tez kapsamında, sınıflandırma ve tematik harita üretiminde temel uydu görüntüsü olarak, çalışma bölgesini içerisine alan 07 Temmuz 2013 tarihinde kaydedilen WV-2 uydu görüntüsü kullanılmıştır. Uydu görüntüsünün 2m konumsal çözünürlüğe sahip 8 spektral bandı ile görüntü kaynaştırma işleminin gerçekleştirilmesi amacıyla 0,5m konumsal çözünürlüğe sahip pankromatik bandı da değerlendirmeye alınmıştır.

Ham haldeki uydu görüntüleri genellikle bir takım hatalar veya eksiklikler içermektedir. Veri içerisindeki hataların düzeltilmesi ve bozuklukların kaldırılması uzaktan algılamada ön işlemler olarak adlandırılmaktadır ve bu operasyonlar görüntünün herhangi bir amaç için kullanımından önce gerçekleştirilmelidir (Mather ve Koch, 2011). Söz konusu düzeltmelerin bir kısmı yer kontrol istasyonlarında gerçekleştirilirken, kullanıcılar tarafından gerçekleştirilmesi gereken düzeltmelerde mevcuttur. Ön işlemler, elde edilen sayısal uydu görüntüsüne ait verilerden istenilen bilgilerin veya özelliklerin elde edilmesi için gerekli olan hazırlıkları içerir ve bunlar radyometrik ve geometrik düzeltmeler olarak sınıflandırılmaktadır. Ön işlemde amaç, algılayıcı ve platformdan kaynaklanan radyometrik ve geometrik bozulmaları ortadan kaldırmaktır. Radyometrik düzeltmeler, algılayıcı düzensizlikleri, istenmeyen algılar, atmosferik gürültülerin düzeltilmesi ve algılayıcı tarafından ölçülen radyasyonun doğru şekilde gösterimi için gerekli dönüşümleri içerir. Uydular tarafından kaydedilen elektromanyetik enerji dünya yüzeyinden algılayıcıya geri dönüşünde atmosfer içerisindeki mevcut gaz ve aerosoller tarafından saçılma ve

yutulma gibi çeşitli etkilere maruz kalırlar. Görüntü üzerindeki bu etkiler atmosferik bozulmalar olarak adlandırılmaktadır. Atmosferik etkiler neticesinde yeryüzündeki nesnelerden yansıyan enerji miktarı ile uydu üzerindeki algılayıcı tarafından kaydedilen enerji miktarı arasında farklılıklar olmaktadır. Atmosferik düzeltme işlemi ile atmosferik etkiler minimize edilerek algılayıcı tarafından kaydedilen yansıma değerlerinin yeryüzündeki yansıma değerlerine dönüşümü gerçekleştirilir.

### **3.3.1 Radyometrik ve atmosferik düzeltmeler**

Uydu görüntüsü ile arazide gerçekleştirilecek spektrometre ölçümlerinin ilişkilendirilebilmesi için ön koşul, söz konusu uydu görüntüsüne atmosferik düzeltme getirilerek parlaklık değeri olarak kaydedilen piksel değerlerinden arazideki spektral yansıma değerlerine geçilmesidir. Bu geçiş sürecinde ilk işlem adımı görüntüdeki piksellerin atmosfer-üstü (top-of-atmosphere) spektral radyans değerlerinin hesaplanmasıdır. WV-2 uydusu üzerindeki algılayıcı 11bit radyometrik çözünürlüğünde veri toplamaktadır. Daha sonra bu 11bit veri 16bit integer olarak veya dosya boyutunu küçültmek amacıyla 8bit'e ölçeklenmektedir. Sonuç görüntünün radyometrik çözünürlüğü ister 16bit ister 8bit olsun, radyometrik düzeltmenin amacı her bir bant için tek bir mutlak kalibrasyon faktörü kullanılarak görüntüdeki tüm piksellerin atmosfer-üstü spektral radyans değerlerinin hesaplanmasıdır. Radyans değerlerinin hesaplanmasının ardından ikinci işlem adımı solar geometrinin belirlenmesidir. Solar geometrinin belirlenmesinde görüntünün kaydedildiği tarih ve zamandan hareketle Julian günü hesaplamaları, Dünya-Güneş uzaklığı ve solar zenit açısı hesabı gibi hesaplamalar gerçekleştirilmektedir. Üçüncü işlem adımında ise atmosfer-üstü spektral radyans değerleri ve solar geometri kullanılarak ham görüntüdeki piksellere ait sayısal numaralardan atmosfer-üstü yansıma değerleri hesaplanmaktadır. Hesaplanan yansıma değerleri tez kapsamında farklı bitki türlerinin tespitinde ve arazide spektrometre ölçümleri ile oluşturulan spektral kütüphaneye direkt olarak ilişkilendirilmesinde kullanılabilecektir (Updike ve Comp, 2010).

WorldView-2 uydu görüntüsü radyometrik olarak düzeltilmiş şekilde kullanıcıya sunulmaktadır. Görüntü üzerindeki piksel değerleri teleskopa ulaşan spektral radyans miktarının bir fonksiyonudur ve algılayıcı bu radyasyonu dijital bir sinyale dönüştürür. Bu sinyal teleskobun spektral emisyonuna ve teleskop içerisine yayılan

multispektral filtrelere, dedektörlerin spektral kuantum etkinliğine ve analogtan sayısala dönüşüm işlemine bağlıdır. Bu nedenle WV-2 görüntüsündeki pikseller tekil bir değere sahiptir ve diğer algılayıcılardan alınan görüntüler ile direkt olarak karşılaştırılmaz. Bunun yerine, görüntü pikselleri en azından atmosfer-üstü spektral radyans değerlerine dönüştürülür. Atmosfer-üstü spektral radyans değerleri 770km yüksekliğindeki WV-2 uydusu üzerindeki teleskopa ulaşan spektral radyans olarak tanımlanmaktadır. WV-2 görüntüleri için, radyometrik olarak düzeltilmiş piksel değerlerinin spektral radyans değerlerine dönüşümünde aşağıda verilen genel eşitlik kullanılmaktadır (Updike ve Comp, 2010).

$$L_{\lambda_{Pixel,Band}} = \frac{K_{Band} \cdot q_{Pixel,Band}}{\Delta\lambda_{Band}} \quad (3.1)$$

Bu eşitlikte  $L_{\lambda_{Pixel,Band}}$  görüntü piksellerinin atmosfer-üstü spektral radyans değerini  $[W \cdot m^{-2} \cdot sr^{-1} \cdot \mu m^{-1}]$ ,  $K_{Band}$  verilen bant için mutlak radyometrik kalibrasyon faktörünü  $[W \cdot m^{-2} \cdot sr^{-1} \cdot count^{-1}]$ ,  $q_{Pixel,Band}$  radyometrik olarak düzeltilmiş pikselleri  $[counts]$  ve  $\Delta\lambda_{Band}$  etkin bant genişliğini  $[\mu m]$  ifade etmektedir. Atmosfer-üstü spektral radyans dönüşümü iki temel işlem adımından oluşur. İlk işlem radyometrik olarak düzeltilmiş piksel değerlerinin uygun mutlak kalibrasyon faktörü ile çarpılması sonucu bant-bütünleşik radyans değerlerinin hesaplanmasıdır. İkinci işlem ise hesaplanan radyans değerlerinin uygun etkili bant genişliğine bölünmesidir. WorldView-2 görüntüsünün her bantı için mutlak radyometrik kalibrasyon faktörleri ve etkili bant genişlik değerleri görüntünün meta veri dosyasında mevcuttur. Her bir WV-2 görüntüsünün meta veri dosyasında radyometrik kalibrasyon değerleri “absCalFactor” ve etkili bant genişliği değerleri “effectiveBandwidth” şeklindeki kısaltmalarla ifade edilmektedir. Çizelge 3.2’de meta veri dosyasında kıyı bandı için örnek değerler gösterilmiştir. Meta veri dosyasında her bir multispektral bant için bu değerler mevcuttur. Çizelgeden de görüleceği üzere BAND\_C, kıyısız (Coastal) banta ait bilgilerin verildiğini ifade etmektedir. Diğer bantlar için bu belirteçler meta veri dosyasında BAND\_B = mavi (Blue); BAND\_G = Yeşil (Green); BAND\_Y = Sarı (Yellow); BAND\_R = Kırmızı (Red); BAND\_RE = Kırmızı Kenar (Red Edge); BAND\_N = Yakın IR1 (NIR1) ve BAND\_N2= Yakın NIR2 (NIR2) şeklinde verilmiştir.

**Çizelge 3.2 :** WV-2 meta veri dosyasında radyometrik kalibrasyon ve etkili bant genişliği değerlerinin gösterimi.

---

BEGIN\_GROUP = BAND\_C

---

...

absCalFactor = 9.295654e-03

effectiveBandwidth = 4.730000e-02

---

END\_GROUP = BAND\_C

---

Daha öncede belirtildiği gibi görüntü üzerindeki piksel değerleri uydu teleskobuna ulaşan spektral radyans miktarının bir fonksiyonudur. Bu atmosfer-üstü spektral radyans değerleri Dünya-Güneş Uzaklığı (Earth-Sun Distance), solar zenit açısı, topoğrafya (solar zenit açısı yeryüzünün düz olduğu kabulü ile hesaplandığından topoğrafya ekstra geometri faktörü olarak dikkate alınır) ve atmosferik etkilere (saçılma ve soğrulma) göre değişkenlik gösterir. Topoğrafya ve atmosferik etkiler basit bir radyometrik düzeltme veya tek bir görüntü olması durumunda ihmal edilebilmektedir. Sonuçta aynı alana ait iki görüntü arasındaki fark solar geometriyi oluşturmaktadır. Bir WV-2 uydu görüntüsü için gerçek solar spektral radyans değerleri görüntü alım sırasındaki Dünya-Güneş uzaklığı ve solar zenit açısına bağlı olarak değişiklik göstermektedir. Bu durum farklı günlerde aynı alanı gösteren iki görüntünün farklı radyans ve görüntü parlaklığına sahip olmasını ortaya çıkarır. Bu aradaki farklılık görüntünün Dünya-Güneş uzaklığı ve solar zenit açısı için düzeltilmesi ile minimize edilebilir. Bant-ortalamalı solar spektral irradyans değerleri (3.2)'de verilen formülle hesaplanır.

$$E_{\lambda_{Band}} = \frac{Esun_{\lambda_{Band}}}{d_{es}^2} \cdot \cos(\theta_s) \quad (3.2)$$

Formülde  $E_{\lambda_{Band}}$  solar zenit açısındaki bant-ortalamalı solar spektral irradyans değerlerini,  $Esun_{\lambda_{Band}}$  Çizelge 4.3'te verilen yeryüzünün normali doğrultusundaki bant-ortalamalı solar spektral irradyans değerlerini,  $d_{es}$  dünya-güneş uzaklığını ve  $\theta_s$  solar zenit açısını ifade etmektedir.

**Çizelge 3.3 :** WorldView-2 görüntüsü için spektral irradyans değerleri.

| Spektral Bant      | Spektral Irradyans [ W-m <sup>-2</sup> -μm <sup>-1</sup> ] |
|--------------------|------------------------------------------------------------|
| Pankromatik        | 1580.8140                                                  |
| Kıyasal            | 1758.2229                                                  |
| Mavi               | 1974.2416                                                  |
| Yeşil              | 1856.4104                                                  |
| Sarı               | 1738.4791                                                  |
| Kırmızı            | 1559.4555                                                  |
| Kırmızı kenar      | 1342.0695                                                  |
| Yakın kızılötesi-1 | 1069.7302                                                  |
| Yakın kızılötesi-1 | 861.2866                                                   |

Herhangi bir WV-2 uydu görüntüsü için Dünya-Güneş uzaklığının hesaplanması için, meta veri dosyasından elde edilen görüntü kaydedilme zamanının Julian gününe çevrilmesi gerekir. Meta veri dosyasında görüntü kayıt zamanı UTC zamanı formatında Çizelge 3.4’te gösterildiği örnek biçiminde bulunmaktadır.

**Çizelge 3.4 :** WV-2 meta veri dosyasında UTC zaman formatındaki görüntü kayıt zamanı verilerinin gösterimi.

|                                                |
|------------------------------------------------|
| BEGIN_GROUP = MAP_PROJECTED_PRODUCT            |
| ...                                            |
| earliestAcqTime = YYYY_MM_DDThh:mm:ss:ddddddZ; |
| ...                                            |
| END_GROUP = MAP_PROJECTED_PRODUCT              |

Çizelgede görüntünün kaydedildiği yıl “YYYY”, ay “MM” ve gün “DD” ile gösterilmiştir. Ünlversal zaman (UT) ise saat (hh), dakika (mm) ve saniye (ss.dddddd) kullanılarak;

$$UT = hh + \frac{mm}{60.0} + \frac{ss.dddddd}{3600.0} \quad (3.3)$$

şeklinde hesaplanır. Buradan hareketle Julian günü (JD) (3.4) yardımıyla hesaplanır.



$$\begin{aligned}
A &= \text{int}\left(\frac{YYYY}{100}\right) \\
B &= 2 - A + \text{int}\left(\frac{A}{100}\right) \\
JD &= \text{int}\left[365.25 \cdot (YYYY + 4716)\right] + \text{int}\left[30.60001 \cdot (MM + 1)\right] \\
&\quad + DD + \frac{UT}{24.0} + B - 1524.5
\end{aligned} \tag{3.4}$$

Julian gününün hesaplanmasının ardından Dünya-Güneş uzaklığı ( $d_{es}$ ) (3.5) yardımıyla hesaplanmaktadır. Genellikle hesaplama sonrası çıkan değer 0.983 ve 1.017 aralığında olup Astronomik birimdedir.

$$\begin{aligned}
D &= JD - 2451545.0 \\
g &= 357.529 + 0.98560028 \cdot D \\
d_{es} &= 1.00014 - 0.01671 \cdot \cos(g) - 0.00014 \cdot \cos(2g)
\end{aligned} \tag{3.5}$$

Güneş açısı görüntüleme alanı boyunca çok küçük miktarda değiştiğinden solar zenit açısının her bir piksel için ayrı ayrı hesaplanmasına gerek yoktur. Bu nedenle ortalama solar zenit açısının kullanılması görüntüdeki her bir piksel için yeterli olmaktadır. WV-2 görüntüsü için ortalama güneş yüksekliği görüntünün merkezi için hesaplanır ve meta veri dosyasında Çizelge 4.5'te verilen örnek şeklinde kullanıcıya sunulur.

**Çizelge 3.5 :** WV-2 meta veri dosyasında ortalama güneş açısı gösterimi.

|                       |
|-----------------------|
| BEGIN_GROUP = IMAGE_1 |
| ...                   |
| meanSunEl = 69.9;     |
| ...                   |
| END_GROUP = IMAGE_1   |

Meta veri dosyasından elde edilen ortalama güneş açısı yardımıyla solar zenit açısı;


$$\theta_s = 90.0 - sunEL \tag{3.6}$$

şeklinde hesaplanabilir. Örneğin  $69.9^\circ$  ortalama güneş yükseklik açısı için hesaplanacak solar zenit açısı  $20.1^\circ$  olacaktır.

Son olarak hesaplanan spektral randays değerleri  $(L_{\lambda_{Pixel}, Band})$ , dünya-güneş uzaklığı,  $(d_{es})$ , bant-ortalamalı solar spektral irradyans değerleri  $(E_{\lambda_{Band}})$  ve solar zenit açısı  $(\theta_s)$  kullanılarak WorldView-2 görüntüsüne ait spektral bantlar için atmosfer-üstü spektral yansımaya değerleri (3.7) yardımıyla hesaplanır.

$$\rho_{\lambda_{Pixel}, Band} = \frac{L_{\lambda_{Pixel}, Band} \cdot d_{es}^2 \cdot \pi}{E_{sun, \lambda_{Band}} \cdot \cos(\theta_s)} \quad (3.7)$$

WorldView-2 uydusu uzaya gönderilme tarihi açısından oldukça yeni bir teknoloji olduğundan birçok uzaktan algılama yazılımında yansımaya değerlerini hesaplayan programlar yeni yeni yer almaktadır. Bu nedenle tez kapsamında WV-2 uydu görüntüsünün atmosfer-üstü yansımaya değerlerinin hesaplanması amacıyla MATLAB yazılımında bir program hazırlanmıştır. Program temel olarak üç temel girdi verisine ihtiyaç duymaktadır (Şekil 3.2). Bu verilerden ilki yansımaya değerleri hesaplanacak olan WV-2 uydu görüntüsüdür. İkinci olarak WV-2 görüntüsüne ait kalibrasyon bilgilerini içeren meta veri dosyasıdır. Programın yansımaya değerlerine dönüşüm işlemi için gereksinim duyduğu son veri ise görüntü ile birlikte servis edilen spektral irradyans değerlerini içeren metin dosyasıdır.



**Şekil 3.2 :** Program başlangıç ekran görüntüsü.

Programda ilk olarak WV-2 uydu görüntüsü ve görüntüye ait özellikler kullanıcı tarafından program ara yüzüne girilmektedir. Uydu görüntüsü programa yüklenebilmesi için görüntü \*.lan formatında olmalı, görüntünün adı, satır-sütun sayıları ve görüntünün bant sayısı Şekil 3.3'te gösterilen girdi ekranında ilgili alanlara yazılmalıdır.

**Şekil 3.3 :** WV-2 görüntüsüne ait temel bilgilerin girildiği program ara yüzü.

Uydu görüntüsünün programa yüklenmesinin ardından hesaplamalar için temel veri kaynağı olarak kullanılan ve görüntünün kalibrasyon parametrelerini içeren meta veri dosyası programa yüklenir. WV-2 görüntüsündeki piksellere ait atmosfer-üstü yansıma değerlerinin hesaplanmasında kullanılan mutlak radyometrik kalibrasyon faktörleri (absCalFactor), etkin bant genişliği (effectiveBandwidth) değerleri, Dünya-Güneş uzaklığı ve Julian gününün hesaplanması için gerekli görüntünün kaydedilme zamanı (earliestAcqTime), solar zenit açısının hesaplanmasında kullanılan ortalama güneş açısı (meanSunEl) değerleri uydu görüntüsü ile birlikte verilen \*.IMD uzantılı meta veri dosyasında bulunmaktadır. Tez kapsamında değerlendirmeye alınan WV-2 görüntüsü için meta veri dosyasından programın otomatik olarak aldığı parametre değerleri Çizelge 3.6’da gösterilmiştir.

**Çizelge 3.6 :** 2013 tarihli WV-2 uydu görüntüsüne ait kalibrasyon değerleri.

| Spektral Bant | absCalFactor    | effectiveBandwidth          | Spektral Irradyans |
|---------------|-----------------|-----------------------------|--------------------|
| BAND_C        | 9.295654e-03    | 4.730000e-02                | 1758.2229          |
| BAND_B        | 1.783568e-02    | 5.430000e-02                | 1974.2416          |
| BAND_G        | 1.364197e-02    | 6.300000e-02                | 1856.4104          |
| BAND_Y        | 6.810718e-03    | 3.740000e-02                | 1738.4791          |
| BAND_R        | 1.851735e-02    | 5.740000e-02                | 1559.4555          |
| BAND_RE       | 6.063145e-03    | 3.930000e-02                | 1342.0695          |
| BAND_N1       | 2.050828e-02    | 9.890000e-02                | 1069.7302          |
| BAND_N2       | 9.042234e-03    | 9.960000e-02                | 861.2866           |
|               | earliestAcqTime | 2013-07-07T09:25:33.996965Z |                    |
|               | meanSunEl       | 69.9                        |                    |

Uydu görüntüsü ve görüntüye ait meta veriler programa yüklendikten sonra atmosfer-üstü yansıma değerlerinin hesaplanması işlemine geçilmektedir. Hesaplamada takip edilen işlem adımları sırasıyla aşağıda verilmiştir.

1. Ham uydu görüntüsündeki piksellerden mutlak kalibrasyon faktörü değerleri ile bant-bütünleşik radyans değerlerine dönüşüm,
2. Hesaplanan bant-bütünleşik radyans değerlerinden etkin bant genişliği değerleri kullanılarak bant-ortalamalı spektral radyans değerlerine dönüşüm,
3. Uydu görüntüleme tarihi ve kayıt zamanı bilgileri yardımıyla Julian gününün ve dünya-güneş uzaklığının hesaplanması,
4. Ortalama güneş açısı yardımıyla solar zenit açısının hesaplanması,
5. Solar geometri ile düzeltilmiş atmosfer-üstü spektral radyans değerlerinin hesaplanması,
6. Hesaplanan spektral radyans değerleri ve spektral irradyans değerleri kullanılarak WV-2 görüntüsündeki piksellerin atmosfer-üstü yansıma değerlerin hesaplanması.

Atmosfer-üstü yansıma değerleri hesaplanan görüntü, tüm görüntü işleme yazılımlarında kolaylıkla açılabilmesi amacıyla \*.BIL formatında kaydedilerek atmosferik düzeltme işlemi tamamlanmaktadır.

### **3.3.2 Geometrik düzeltmeler**

Uydu görüntülerinin radyometrik ve atmosferik düzeltmelerinin yapılmasının ardından geometrik düzeltme (ortorektifikasyon) işlemi gerçekleştirilmiştir. Geometrik düzeltmenin amacı, görüntüler üzerindeki geometrik bozuklukların giderilerek görüntünün ortak bir projeksiyon sistemine kaydedilmesidir. Geometrik sapmaların birçoğu sistematik olduğundan uygun modeller oluşturularak giderilebilir. Sistematik olmayan veya rastgele hatalar modellenemez. Geometrik düzeltme işlemi ile ham haldeki uydu görüntüsü, resim koordinat sisteminden, görüntü üzerinde ve arazideki koordinatları bilinen uygun sayı ve konumdaki yer kontrol noktaları yardımıyla arazi koordinat sistemine dönüştürülür. Bu işleme görüntüden haritaya geçiş denir. Ham haldeki görüntünün geometrik olarak düzeltilmesinde kullanılan bir diğer yöntem görüntüden görüntüye dönüşümdür. Bu yöntemde daha önce coğrafik olarak koordinatlandırılmış diğer bir görüntü yardımıyla, her iki görüntüdeki ortak noktalar kullanılarak geometrik düzeltme işlemi gerçekleştirilir (Mather ve Koch, 2011).

Uydu görüntüleri geometrik olarak düzeltilip kullanıcı tarafından belirlenmiş herhangi bir koordinat sistemine bağlandıktan sonra ortaya çıkan görüntü eğiminden


dolayı oluşan piksellere yeni değerlerin atanması gerekir. Diğer bir ifadeyle, geometrik olarak düzeltilmiş görüntü üzerindeki piksellere ait sayısal bilgiler geometrik dönüşüm sonucunda olması gerekenden farklı olabilirler. Bu nedenle düzeltilmiş görüntüdeki yeni piksellerin sayısal değerlerinin belirlenmesinde yeniden örnekleme adı verilen bir işlem kullanılır. Yeniden örnekleme ile geometrik dönüşüm öncesinde görüntüdeki orijinal sayısal piksel değerleri yardımıyla yeni piksel değerleri hesaplanır. En yakın komşuluk, bilineer enterpolasyon ve kübik eğri olarak bilinen üç farklı yöntem yeniden örnekleme işleminin gerçekleştirilmesinde kullanılmaktadır (Mather ve Koch, 2011).

Tez kapsamında, WV-2 uydu görüntüsünün geometrik olarak düzeltilmesinde mevcut halihazır haritalar, yüksek çözünürlüklü uydu görüntüleri ve arazide gerçekleştirilen GPS ölçülerinden yararlanılmıştır. Ortorektifikasyon işlemi sonucunda görüntüler Universal Transverse Mercator (UTM) projeksiyon sisteminde WGS84 datumunda tanımlanmıştır. Görüntünün geometrik olarak düzeltilmesi ve UTM koordinat sistemine dönüşümünde tüm çalışma alanına homojen olarak dağıtılan 20 yer kontrol noktası kullanılarak birinci derece Afin dönüşümü yardımıyla yaklaşık 0,5 piksel karesel ortalama ile düzeltme işlemi gerçekleştirilmiştir. Yeniden örnekleme işleminde görüntü netliği ve detayların korunması açısından bilineer interpolasyon yöntemi tercih edilmiştir.

### **3.3.3 Görüntü kaynaştırma**

Radyometrik ve geometrik olarak düzeltilen 2m konumsal çözünürlüklü multispektral Worldview-2 görüntüsü ile 0,5m konumsal çözünürlüğe sahip pankromatik görüntünün kaynaştırılmasında ton-doygunluk-yoğunluk (HSI) dönüşümü, Brovey dönüşümü, temel bileşenler analizi (PCA) ve Gram-Schmidt (GS) algoritmaları kullanılmıştır. Söz konusu algoritmalar kullanılarak gerçekleştirilen dönüşümler sonucu elde edilen görüntüler örnek bir alan üzerinde Şekil 3.4'de gösterilmiştir. Şekilde kaynaştırma sonucu elde edilen görüntülere ilave olarak aynı bölgeye ait WV-2'nin 2m çözünürlüklü kırmızı-yeşil-mavi bant kombinasyondaki multispektral görüntü (Şekil 3.4a) ve 0,5m çözünürlüklü pankromatik görüntüsü (Şekil 3.4b) hazırlanmıştır. Şekilden de görüleceği üzere HSI (Şekil 3.4c) ve Brovey (Şekil 3.4d) dönüşümleri sonucunda elde edilen görüntüler görsel olarak ele alındığında, orijinal multispektral görüntüdeki renk dağılımının söz konusu

görüntülerde ortadan kaybolduğu görülmektedir. PCA (Şekil 3.4e) ve GS (Şekil 3.4f) dönüşümleri ile elde edilen görüntülerin bu ölçekte görsel olarak karşılaştırılabilmesi oldukça güç olup, HSI ve Brovey görüntülerine göre gerçeğe daha yakın renk dağılımında oldukları ifade edilebilir.



**Şekil 3.4 :** Kaynaştırma işlemi sonucunda elde edilen görüntüler.  
(a) Multispektral WV-2 görüntüsü (2m), (b) pankromatik WV-2 görüntüsü, (c) HSI dönüşümü, (d) Brovey dönüşümü, (e) PCA dönüşümü ve (f) GS dönüşümü.

Kullanılan dönüşüm algoritmalarının kaynaştırma işlemindeki performanslarının değerlendirilmesinde entropi ölçütü kullanılmıştır. Entropi bir görüntünün temsil edilebilmesi için gerekli olan bit sayısı ile ilgili bir değerlendirme ölçütüdür (Karathanassi ve diğ, 2007; Mather ve Koch, 2011). Dönüşüm sonucunda elde edilen görüntülerin kırmızı, yeşil ve mavi bantlarının her biri ve karşılaştırma amacıyla orijinal multispektral görüntünün kırmızı, yeşil ve mavi bantları için entropi değerleri hesaplanmış ve elde edilen istatistik değerler Çizelge 3.7’de verilmiştir. Çizelgede kaynaştırma sonucu elde edilen görüntülere ait istatistik değerlerin yanında WV-2’nin RGB bandına ait istatistik değerlerde verilmiştir. Çizelge incelendiğinde GS ve PCA dönüşümleri sonucunda kırmızı, yeşil ve mavi bant için hesaplanan entropi değerleri HSI ve Brovey dönüşümleri sonucunda elde edilen entropi değerlerinden yüksektir. GS ve PCA metodları için hesaplanan entropi değerleri birbirine çok yakın olup GS algoritması ile üretilen kırmızı, yeşil ve mavi bantlara ait entropi değerleri daha yüksektir. Bu nedenle tez kapsamında multispektral WV-2 uydu görüntüsü ile pankromatik görüntünün kaynaştırılmasında Gram-Schmidt (GS) dönüşümü kullanılmıştır ve elde edilen görüntü uygulamalarda dikkate alınmıştır.

**Çizelge 3.7 :** Kaynaştırma sonucu elde edilen görüntüler için hesaplanan entropi değerleri.

|         | WV-2 (RGB) | HSI  | Brovey | PCA  | GS   |
|---------|------------|------|--------|------|------|
| Kırmızı | 1,07       | 0,45 | 0,82   | 1,14 | 1,17 |
| Yeşil   | 1,30       | 0,67 | 0,94   | 1,32 | 1,35 |
| Mavi    | 0,56       | 0,04 | 0,59   | 0,60 | 0,65 |

### 3.4 Spektral Ölçümler ve Spektral Kütüphane Oluşturma Çalışmaları

Tez kapsamında önerilen yaklaşımın işlerliğinin test edilmesi amacıyla çalışma alanı içerisinde öncelikli olarak saha çalışması yapılarak mevcut ağaç türleri çeşitliliği belirlenmiş, ardından spektral ölçümler için esas olacak örnekleme alanları tespit edilmiştir.

#### 3.4.1 Gerçekleştirilen saha çalışmaları

Gebze Teknik Üniversitesi Çayırova Kampüsü’nü içerisine alan yaklaşık 220 hektarlık bir alan içerisinde bulunan ağaç türleri incelenmiş ve Çizelge 3.8’de isimleri ve özellikleri belirtilen 9 farklı ağaç türünün mevcut olduğu tespit edilmiştir. Tablodan da görüleceği üzere tespit edilen ağaç türlerinden 4 tanesi iğne yapraklı ve

yaprak fenolojisi açısından yaprak dökmeyen ağaç türlerinden iken 5 tanesi geniş yapraklı ve fenolojik açıdan yaprak döken ağaç türlerinden oluşmaktadır.

**Çizelge 3.8 :** Çalışma alanı içerisindeki ağaç türlerine ait bilgiler.

| Ağaç adı    | Bilimsel Adı             | Familya      | Tip            | Yaprak Fenolojisi |
|-------------|--------------------------|--------------|----------------|-------------------|
| Ayva        | Cydonia Oblonga          | Rosaceae     | Geniş yapraklı | Yaprak döken      |
| Ceviz       | Juglans                  | Juglandaceae | Geniş yapraklı | Yaprak döken      |
| Çınar       | Platanus orientalis L.   | Platanaceae  | Geniş yapraklı | Yaprak döken      |
| Karakavak   | Populus nigra L.         | Salicaceae   | Geniş yapraklı | Yaprak döken      |
| Zeytin      | Olea Europaea            | Oleaceae     | Geniş yapraklı | Yaprak döken      |
| Fıstık Çamı | Pinus Pinea              | Pinaceae     | İğne yapraklı  | Yaprak dökmeyen   |
| Kızılçam    | Pinus Brutia Ten.        | Pinaceae     | İğne yapraklı  | Yaprak dökmeyen   |
| Sedir       | Cedrus                   | Pinaceae     | İğne yapraklı  | Yaprak dökmeyen   |
| Servi       | Cupressus<br>Empervirens | Cupressaceae | İğne yapraklı  | Yaprak dökmeyen   |

Söz konusu ağaç türlerine ilişkin spektral yansıma özelliklerinin belirlenmesi amacıyla arazide tespit edilen test noktalarının çalışma alanındaki dağılımı Şekil 3.5'te gösterilmiştir. Şekil incelendiğinde özellikle çalışma alanının kuzey bölümünde iğne yapraklı çam ağaçlarının yoğunlaştığı görülmektedir. Arazide yapılan incelemelerde söz konusu alan içerisinde benzer spektral özelliklere sahip aynı familyadan fıstık çamı (*Pinus Pinea*) ve kızılçam (*Pinus Brutia Ten.*) ağaçlarının varlığı tespit edilmiştir. Çalışma bölgesinin batı kesiminde ise ayva (*Cydonia Oblonga*), zeytin (*Olea Europaea*) ve fıstık çamı (*Pinus Pinea*) ağaçlarının bulunduğu görülmektedir. Çalışma bölgesinin doğu kesiminde ise çınar (*Platanus orientalis L.*) ve fıstık çamı (*Pinus Pinea*) ağaçlarının birbirine komşu alanlarda konumlandığı görülmektedir. Çalışma alanının orta kesiminde ise tespit edilen ağaç türlerinin karışık halde bulunduğu belirlenmiştir.

Spektral ölçümlerin uydu görüntü çekim tarihi ile aynı süreçte gerçekleştirilmesi esas olduğundan, uydu görüntüsünün kaydedildiği zaman aralığını kapsayan 2013 Temmuz ayının ilk haftası içerisinde Şekil 3.5'de konumları ile gösterilen 14 noktada ağaç türlerinden örnekler alınarak ASD FieldSpec3 spektrometre cihazı ile spektral ölçümler gerçekleştirilmiştir.





Şekil 3.5 : Spektral ölçümler için belirlenen örnekleme noktalarının dağılımı.

### 3.4.2 Spektroradyometre ölçümleri ve spektral özelliklerin analizi


Tez kapsamında çalışma alanı içerisindeki farklı ağaç türlerine ait spektral özelliklerin belirlenmesi ve detaylı analizler yapılabilmesi amacıyla spektral kütüphaneler oluşturulması hedeflenmiştir. Spektral kütüphaneler kullanılarak, farklı ağaç ve bitki türlerine ait spektral yansımalar arasındaki ilişki ortaya konulabilmektedir. Spektral kütüphane oluşturma çalışmalarında takip edilen temel işlem adımları Şekil 3.6'dan da görüleceği üzere, çalışma alanı içerisinde spektral ölçümleri yapılacak olan ağaç türlerinin belirlenmesi, belirlenen ağaç türlerine ait örnekler için spektral ölçülerin gerçekleştirilmesi, spektral ölçüler üzerinden her bir örneğin yansımaya özelliklerinin analizi, benzer spektral özelliklere sahip ağaç türlerine ait yansımaya özelliklerinin bir arada değerlendirilerek analiz edilmesi ve oluşturulan yansımaya eğrilerinden spektral kütüphaneye esas olacak spektral eğrilerin oluşturulması şeklindedir.



**Şekil 3.6 :** Spektral kütüphane oluşturulmasında takip edilen temel işlem adımları.

Spektral ölçümler sonucu oluşturulan spektral kütüphanenin uydu görüntüleri ile ilişkilendirilmesi amacıyla spektral ölçümler uydu görüntüsünün çekim tarihine paralel olarak tüm bitki türlerinin en canlı ve yansımaya değerlerinin en yüksek olduğu Temmuz ayı içerisinde gerçekleştirilmiştir. Tez kapsamında değerlendirmeye alınan 9 farklı ağaç türü için, arazi çalışmaları ile tespit edilen 14 noktadan alınan numunelere ait spektral yansımaya özelliklerinin belirlenmesinde ASD (Analytical Spectral Devices) FieldSpec3 spektrodijital ölçüm cihazı kullanılmıştır (Şekil 3.7). 350nm ile 2.500nm spektral aralığında algılama yapabilme özelliğine sahip FieldSpec3 spektrodijital ölçüm cihazı kullanılarak örnekleme alanından toplanan her bir numunenin 15 tekrarlı yansıtım değeri ölçülmüştür. FieldSpec3 spektrodijital ölçüm cihazı ile numunelere ait spektral ölçüm işleminin gerçekleştirilmesinde güneş ışığına ihtiyaç duymadan ve ilgi duyulan nesneye temas edilerek spektral ölçümlerin gerçekleştirilmesine imkan sağlayan ASD High Intensity Contact Probe aparatı kullanılmıştır. Contact Probe aparatının uygulamalarda kullanılmasının en büyük avantajı güneş enerjisine ihtiyaç duymayıp kendi aydınlatma özelliğini kullanarak ilgi duyulan nesneye direkt temas ile kullanılmasıdır. Cihaz sahip olduğu optik tasarımı ile dağınık şekilde gelen yansımaya hatalarının minimize edilmesine ve örneklerin laboratuvar ortamında da değerlendirilmesine olanak sağlamaktadır. Her bir spektral yansıtım değeri ölçümünden önce cihazın kalibrasyonu ASD firması tarafından özel üretilen beyaz referans paneli (spectralon) kullanılarak gerçekleştirilmiştir. Numunelerin toplanması ve spektral ölçümler 4-11 Temmuz 2013 tarihleri arasında gerçekleştirilmiştir. Her


bir örnek için 15 tekrarlı yansıtım değeri ölçülmüş ve ölçülere ait spektral yansıtım eğrileri elde edilmiştir. Gerçekleştirilen spektral ölçümler ilk olarak kendi içerisinde değerlendirilip analiz edilmiştir. Daha sonra her bir örneğe ait ortalama yansıtım eğrileri hesaplanarak, 9 farklı ağaç türüne ait spektral yansıtım özellikleri ve yansımalar arasındaki ilişkiler bir arada değerlendirilmiştir.



**Şekil 3.7 :** ASD FieldSpec3 ile Sedir ağacına ait spektral özelliklerin belirlenmesi.

Şekil 3.8’de çalışma alanı içerisinde tespit edilen 5 farklı geniş yapraklı ağaç türüne ilişkin spektral ölçümlere ait yansıtım eğrileri görülmektedir. Söz konusu geniş yapraklı ağaç türlerine ilişkin spektral eğriler genel olarak incelendiğinde spektral yansıtım değerlerinin özellikle kıvırlötesi (NIR) bölgede tüm bitki türleri için en yüksek seviyelerde olduğu görülmektedir. Bu açıdan ele alındığında, en yüksek spektral yansıtım değerinin Şekil 3.8b’de görüleceği üzere Karakavak (*Populus nigra* L.), en düşük yansıtım değerinin ise Ayva (*Cydonia Oblonga*) ağacı (Şekil 3.8a) örneğinden elde edildiği görülmektedir. Diğer taraftan tüm geniş yapraklı bitki türleri için özellikle görünür bölgede ölçülen spektral yansıtım değerlerinin % 20’den düşük olduğu görülmektedir. Görünür bölgede en yüksek yansıtım değerlerinin klorofil soğurmasının en az olduğu yeşil bant aralığında olduğu tespit edilmiştir. Geniş yapraklı ağaç türleri için elde edilen bu bulgulara, söz konusu türlerin görünür bölgede ayırt edilmesinin güç olduğunu, yüksek yansıtım değerlerinin gözlemlendiği kıvırlötesi bölgede söz konusu ayırımın yapılabileceğini destekler niteliktedir.






**Şekil 3.8 :** Geniş yapraklı ağaç türlerine ait ölçülen spektral yansım eğrileri:  
a) Ayva; b) Karakavak; c) Ceviz; d) Zeytin ve e) Çınar.


Çalışma bölgesindeki 4 farklı iğne yapraklı ağaç türünden alınan numuneler içinde spektral ölçümler gerçekleştirilmiş ve elde edilen spektral yansım eğrileri Şekil 3.9’da verilmiştir. Şekil incelendiğinde tüm iğne yapraklı ağaç türlerine ait spektral yansım eğrilerinin kıvılotesi bölgede yüksek yansım değerlerine sahip olduđu görölmektedir. İğne yapraklı ağaç türlerine ait spektral yansım eğrileri içerisinde kıvılotesi bölgede en yüksek yansım değerlerine sahip olan türün Sedir (*Cedrus*) ağacı (Şekil 3.9c) olduđu, diğr taraftan aynı spektral bölgede Fıstık Çamı’nın (*Pinus Pinea*) yansım değerlerinin (Şekil 3.9a) en düşük düzeyde olduđu görölmektedir. Görünür bölgede ise yansım değerlerinin %20’nin altında kaldıđı gözlemlenmiştir. Bu durum iğne yapraklı ağaç türlerinin spektrumun görünür bölgesinde benzer spektral karakteristiğe sahip olduđu ve söz konusu bitki türlerinin bu spektral

bölgede birbirinden ayırt edilebilirliğinin düşük olduğu şeklinde yorumlanabilmektedir. Diğer taraftan, yüksek spektral yansımaya değerlerinin elde edildiği kızılötesi bölgede benzer spektral özelliklere sahip iğne yapraklı ağaç türleri arasında spektral ayırmanın daha kolay yapılabileceği görülmektedir.



**Şekil 3.9 :** İğne yapraklı ağaç türlerine ait ölçülen spektral yansımaya eğrileri: a) Fıstık Çamı; b) Kızılçam; c) Sedir ve d) Servi.

Çalışma alanındaki iğne ve geniş yapraklı ağaç türleri için yapılan spektral ölçümlerin ardından, her bir ağaç türü için gerçekleştirilen 15 spektral ölçümün ortalaması alınarak spektral kütüphane için esas ortalama spektral yansımaya eğrileri elde edilmiş ve Şekil 3.10’da gösterilmiştir. Şekilde hesaplanan ortalama yansıtım eğrilerinin yanı sıra yorumlama ve analiz amacıyla tez kapsamında kullanılan WorldView-2 uydu görüntüsü sahip olduğu 8 bandın (kıyı, mavi, yeşil, sarı, kırmızı, kırmızı-kenar, kızılötesi-1 ve kızılötesi-2) elektromanyetik spektrum (EMS) içerisinde kapsadığı bölgeler ayrı ayrı gösterilmiştir.



Şekil 3.10 : Geniş ve iğne yapraklı ağaç türlerine ait spektral yansıtım eğrileri.


Şekildeki ortalama yansıtım eğrileri incelendiğinde, özellikle EMS’da görünür bölge olarak bilinen 380 - 720nm dalga boyu aralığının da 9 ağaç türünün de benzer spektral karakteristiğe sahip olduğu görülmektedir. Söz konusu spektral bölge içerisinde özellikle WV-2 uydusunun yeşil bandının kapsadığı spektral aralıkta en yüksek spektral yansıtım değeri (%16) iğne yapraklı ağaç türlerinden Sedir (*Cedrus*) ağacı için hesaplanırken, en düşük yansıtım değeri (%7) geniş yapraklı ağaç türlerinden Ayva (*Cydonia Oblonga*) ağacı için hesaplanmıştır. WV-2 görüntüsünün kıyı, mavi, sarı ve kırmızı bantlarına karşılık gelen spektral aralıklarda ise söz konusu ağaç türlerinin birbirlerinden spektral olarak ayırt edilmesinin oldukça güç olduğu görülmektedir. Elde edilen sonuçlardan hareketle, çalışma alanındaki 9 farklı ağaç türünün görünür bölgede benzer spektral özellikler gösterdiği ve WV-2 uydusunun görünür bölge içerisinde algılama yaptığı spektral bantlar ile söz konusu ağaç türlerinin birbirinden ayırt edilmesinin oldukça güç olduğu söylenebilmektedir.

Ağaç türleri için oluşturulan ortalama spektral eğriler incelendiğinde özellikle EMS’un yakın kızılötesi olarak bilinen 720-1300nm aralığındaki spektral aralıkta spektral yansıma değerlerinin dikkat çekici bir biçimde artış gösterdiği görülmektedir. Bunun temel nedeni yeşil yaprağın bu bölgede çok az enerjiyi soğurması ve enerjinin büyük bir kısmını yansıtması ile açıklanmaktadır. Ağaç türlerinin spektral yansıma karakteristikleri yakın kızılötesi bölgesinde ele alındığında, özellikle geniş yapraklı ağaç türleri ile iğne yapraklı ağaç türlerinin birbirlerinden net olarak ayırt edilebildiği görülmektedir. Nitekim yakın kızılötesi bölgede geniş yapraklı ağaç türlerinden Karakavak (*Populus nigra L.*) için hesaplanan yansıtım değeri %97 iken iğne yapraklı ağaç türlerinden en yüksek yansıtım değeri %61 olarak Sedir (*Cedrus*) ağacı için hesaplanmıştır. Elde edilen bu sonuçlar, geniş ve iğne yapraklı ağaç türlerinin yakın kızılötesi bölgede birbirlerinden ayırt edilebilir olduğu ve WV-2 uydu görüntüsünün sahip olduğu kırmızı kenar, kızılötesi-1 ve kızılötesi-2 bantları ile bu ayrımın tespit edilebileceği söylenebilir. İğne ve geniş yapraklı ağaç türlerine ait ortalama spektral yansıtım eğrileri kendi içerisinde ele alındığında önemli sonuçlara ulaşılmıştır. Bunlardan ilki, çalışma alanı içerisindeki iğne yapraklı ağaç türlerinin yakın kızılötesi bölgede birbirlerinden ayırt edilebilir olmasıdır. Bu bölge içerisinde en yüksek spektral yansıtım değeri Sedir (*Cedrus*) ağacı için %61 iken, en düşük yansıtım değeri %41 ile Fıstık Çamı’na (*Pinus Pinea*) aittir. Diğer iki iğne yapraklı ağaç türlerinden

Kızılçam'ın (*Pinus Brutia Ten.*) spektral yansıtım değeri %50, Servi (*Cupressus Empervirens*) ağacı için yansıtım değeri %57 olarak hesaplanmıştır. Elde edilen önemli sonuçlardan bir diğeri ise yakın kızılötesi bölgede geniş yapraklı ağaç türlerinin de birbirlerinden büyük ölçüde ayırt edilebilir olmasıdır. Bu spektral aralıkta geniş yapraklı ağaç türleri içerisinde en yüksek yansıtım değeri %97 olarak Karakavak (*Populus nigra L.*) için, en düşük spektral yansıma ise %82 değeriyle Ayva (*Cydonia Oblonga*) ağacına aittir. Bu iki geniş yapraklı ağaç türü elektromanyetik spektrumun bu bölgesinde net olarak birbirinden ayırt edilebilirken, diğer geniş yapraklı bitki türlerinin (Ceviz (*Juglans*); Zeytin (*Olea Europaea*) ve Çınar (*Platanus orientalis L.*) bazı spektral dalga boyu aralıklarında benzer spektral davranışlar sergilediği görülmektedir. Bu durumun, özellikle WV-2 görüntüsünün sınıflandırılması ile üretilen tematik haritada söz konusu ağaç türlerine ait piksellerin birbirlerine karışmasına neden olabileceği düşünülmektedir.

### 3.4.3 Spektral kütüphanelerin oluşturulması

Tez kapsamında çalışma alanında gerçekleştirilen spektral ölçümler ENVI (5.2) veri analiz programı yardımıyla derlenip, spektral yansıma eğrileri kullanarak ağaç türleri için spektral kütüphane oluşturulmuştur (Şekil 3.11). Söz konusu kütüphane, ağaç türlerinin birbirinden spektral olarak ayırt edilebilirliğinin incelenmesi ve uydu görüntüsü üzerinden örnekleme alanlarının belirlenmesinde kullanılmıştır.




Şekil 3.11 : Spektral ölçümleri gerçekleştirilen ağaç türlerine ait spektral kütüphane.



Spektral kütüphanesi oluşturulan türlerin spektral olarak birbirlerine olan benzerlikleri Spektral Özellik Eşleştirme (Spectral Feature Fitting, SFF) algoritması kullanılarak istatistiksel olarak analiz edilmiştir. En küçük kareler prensibine dayalı olan algoritma bir referans spektral eğri ile spektral kütüphanedeki diğer eğrilerin kıyaslanması esasına dayanmaktadır (Clark ve diğ., 1990). Analiz neticesinde referans alınan eğrinin diğer spektral eğrilerle olan benzerliği belirlenmektedir.

SFF algoritması ile elde edilen istatistiksel sonuçlar Şekil 3.12’de her bir ağaç türü için hazırlanan bir grafik üzerinde gösterilmiştir. Şekil incelendiğinde Kızılcıam (*Pinus Brutia Ten.*) ağacıyla en yüksek benzerlik iğne yapraklı Sedir (*Cedrus*) ağacı için hesaplanırken, en düşük benzerliğin geniş yapraklı Ayva (*Cydonia Oblonga*) ağacı ile olduğu görülmüştür. Diğer iğne yapraklı Fıstık Çamı (*Pinus Pinea*) için hesaplanan istatistik değerleri ele alındığında en yüksek benzerliğin Sedir (*Cedrus*) ağacıyla, en düşük benzerliğin ise Ayva (*Cydonia Oblonga*) ağacıyla olduğu görülmektedir. Servi (*Cupressus Empervirens*) ağacının diğer ağaç türleriyle olan benzerliği incelendiğinde en yüksek benzerliğin Sedir (*Cedrus*), en düşük benzerliğin ise Ayva (*Cydonia Oblonga*) ağacı olduğu tespit edilmiştir.




Şekil 3.12 : SFF algoritması ile elde edilen sonuçların grafiksel gösterimi.

Elde edilen bu bulgular iğne ve geniş yapraklı ağaç türlerinin birbirlerinden spektral olarak farklı olduklarını ve birbirlerinden ayırt edilmelerinin daha kolay olduğunu destekler niteliktedir. Diğer taraftan iğne yapraklı ağaç türleri kendi içerisinde ele alındığında, tüm iğne yapraklı ağaç türlerinin Sedir (*Cedrus*) ağacı ile yüksek spektral benzerliğe sahip olduğu görülmektedir. Bu nedenle iğne yapraklı ağaç türlerinin sınıflandırılmasında, Sedir (*Cedrus*) ağacına ait piksellerle diğer iğne yapraklı ağaçlara ait piksellerin birbirine karışması ya da hatalı sınıflandırılması söz konusu olabilecektir.

Geniş yapraklı ağaç türleri kendi içerisinde analiz edildiğinde Karakavak (*Populus nigra* L.) ve Ceviz (*Juglans*) ağaç türlerinin spektral olarak diğer türlere olan benzerlikleri dikkat çekmektedir. Örneğin, Ayva (*Cydonia Oblonga*) ağacına spektral olarak benzerlik gösteren en yakın ağaç türü Karakavak (*Populus nigra* L.) ağacıdır, Karakavak (*Populus nigra* L.) ağacı ise Ceviz (*Juglans*) ağacıyla spektral olarak benzerlik göstermektedir. Zeytin (*Olea Europaea*) ve Çınar (*Platanus orientalis* L.) ağaçlarının diğer geniş yapraklılara olan spektral benzerliği incelendiğinde, söz konusu ağaç türlerinin her ikisinin de Ceviz (*Juglans*) ağacı ile yüksek benzerliğe sahip olduğu ifade edilebilir.


Atmosfer üstü yansıma değerleri hesaplanan WV-2 uydu görüntüsüyle spektral kütüphanenin ilişkilendirilmesi amacıyla spektral kütüphane WV-2 görüntüsünün multispektral bantlarının merkez dalga boyu aralıkları dikkate alınarak yeniden örneklenmiştir. Örneklem sonucunda elde edilen spektral kütüphane, WV-2 görüntüsünün multispektral bant aralıkları ve bantlara ilişkin merkez dalga boyları Şekil 3.13’de gösterilmiştir. Şekil incelendiğinde WV-2 görüntüsünün kırmızı kenar, kırmızı-1 ve kırmızı-2 bantlarının iğne ve geniş yapraklı ağaç türlerinin birbirlerinden ayırt edilmesinde noktasında kritik öneme sahip olduğu görülmektedir. Kırmızı-1 ve kırmızı-2 bantlarda iğne yapraklı servi, sedir, kızılçam ve fıstık çamı türlerinin birbirlerinden ayırt edilebilir olduğu görülmektedir. Buna karşın aynı spektral bantlarda zeytin ve çınar ağaçları arasındaki ayrımın zor olduğu görülmektedir. Geniş yapraklı ağaç türlerinden karakavak ve ayva ağaçlarının diğer ağaç türlerine göre bu bantlarda daha kolay ayırt edilebildiği söylenebilir.



Şekil 3.13 : WV-2 spektral bant aralığına ölçeklenen spektral kütüphane.

### 3.5 Sınıflandırma Öncesi Gerçekleştirilen Ön Hazırlıklar

Sınıflandırma işleminde genel olarak kontrollü ve kontrolsüz sınıflandırma olarak bilinen iki yaklaşım vardır. Tez çalışmasında yüksek sınıflandırma doğruluğu ürettiği birçok uygulamada ortaya konulan kontrollü sınıflandırma yaklaşımı tercih edilmiştir. Tez kapsamında yardımcı veriler ile desteklenen veri setlerinin sınıflandırılmasında piksel ve obje tabanlı kontrollü sınıflandırma yaklaşımları kullanılmıştır. Sınıflandırma sonuçlarının objektif olarak karşılaştırılması amacıyla her iki yaklaşımda da aynı sınıflandırma algoritmaları değerlendirmeye alınmıştır. Tez kapsamında benzer spektral özelliklere sahip nesnelerin sınıflandırılması ve tematik harita üretiminde takip edilen temel işlem adımları Şekil 3.14’de gösterilmiştir.



Şekil 3.14 : Sınıflandırma ve tematik harita üretiminde takip edilen işlem adımları.

### 3.5.1 Yardımcı verilerin oluşturulması

Tez kapsamında WV-2 uydu görüntüsü ile arazi örtüsü/kullanımına yönelik tematik harita üretiminde yardımcı veri seti olarak, çeşitli vejetasyon indeksleri, temel bileşenler analizi ile belirlenen bileşenler, gri düzey oluşum matrisi yardımıyla hesaplanan doku özellikleri ve ton-doygunluk-yoğunluk dönüşümü ile elde edilen bileşenler kullanılmıştır.

Vejetasyon indeksleri başta arazi örtüsü/kullanımı tespitinde olmak üzere ormancılık, rekolte tahmini ve ürün sağlığı gibi bir çok uygulamada temel veri kaynağı olarak kullanılmaktadır. Günümüze kadar literatürde birçok vejetasyon indeksi tanımlanmış ve uygulamalarda kullanılmıştır. Tez kapsamında WV-2 uydu görüntüsünün yeni bantlarını da kullanan 12 farklı vejetasyon indeksi (Çizelge 3.9) yardımcı veri seti olarak hesaplanmış ve her bir indeks için tematik harita üretilmiştir. Hesaplamalarda atmosferik olarak düzeltilen ve yansıma değerleri hesaplanan uydu görüntüsü kullanılmıştır.

**Çizelge 3.9 :** Çalışmada değerlendirmeye alınan vejetasyon indeksleri.

| Vejetasyon İndeksi                                            | Formül                                                                                           |
|---------------------------------------------------------------|--------------------------------------------------------------------------------------------------|
| Normalleştirilmiş fark bitki örtüsü indeksi- 1                | $NDVI - 1 = \frac{NIR2 - Kırmızı}{NIR2 + Kırmızı}$                                               |
| Normalleştirilmiş fark bitki örtüsü indeksi - 2               | $NDVI - 2 = \frac{NIR1 - Kırmızı}{NIR1 + Kırmızı}$                                               |
| Normalleştirilmiş fark bitki örtüsü indeksi - 3               | $NDVI - 3 = \frac{NIR2 - Kırmızı kenar}{NIR2 + Kırmızı kenar}$                                   |
| Normalleştirilmiş toprak indeksi                              | $NDSI = \frac{Sarı - Yeşil}{Sarı + Yeşil}$                                                       |
| Homojen olmayan özellik farkı                                 | $NHFD = \frac{Kırmızı kenar - Kıyı}{Kırmızı kenar + Kıyı}$                                       |
| Geliştirilmiş bitki örtüsü indeksi                            | $EVI = 2,5 \times \frac{NIR2 - Kırmızı}{NIR2 + 6 \times NIR2 - 7,5 \times Mavi + 1}$             |
| Düzenlenmiş toprak etkisi azaltılmış vejetasyon indeksi       | $MSAVI = \frac{2 \times NIR2 + 1 - \sqrt{(2 \times NIR2 + 1)^2 - 8 \times (NIR2 - Kırmızı)}}{2}$ |
| Orman ve bitki indeksi                                        | $FCI = \frac{NIR1 - Kırmızı kenar}{NIR1 + Kırmızı kenar}$                                        |
| Toprak etkisi azaltılmış vejetasyon indeksi                   | $SAVI = (1 + L) \times \frac{NIR2 - Kırmızı}{NIR2 + Kırmızı + L}$                                |
| Atmosferik koşullara dayanıklı bitki indeksi                  | $ARVI = \frac{NIR2 - 2 \times Kırmızı + Mavi}{NIR2 + 2 \times Kırmızı - Mavi}$                   |
| Optimize edilmiş toprak etkisi azaltılmış vejetasyon indeksi  | $OSAVI = \frac{NIR2 - Kırmızı}{NIR2 + Kırmızı + 0,16}$                                           |
| Temel bileşen ve kızılötesi bant ile normalleştirilmiş indeks | $PCABI = \frac{PCA1 - NIR2}{PCA1 + NIR2}$                                                        |

\*NIR1:Kızılötesi-1, NIR2:Kızılötesi-2, PCA1: İlk temel bileşen, L:Düzeltilme faktörü



Uzaktan algılanmış görüntülerin sınıflandırılmasında kullanılan bir diğer yardımcı veri seti doku özellikleridir. Düzenli bir frekansta tekrar eden desen ve/veya desen kombinasyonu olarak tanımlanan doku bir görüntüdeki ilgi duyulan objeleri tanımlanmasında kullanılan önemli bir karakteristiktir. Doku özellikleri iki komşu piksel arasındaki uzaklık ve açı ilişkilerinin bir fonksiyonu olarak tanımlanan gri düzey oluşum matrislerinden hesaplanmaktadır. Tez kapsamında yardımcı veri olarak kullanılan doku özellikleri Çizelge 3.10’de formülleri ile birlikte verilmiştir. Söz konusu doku parametrelerinin hesaplanmasında 3x3 pencere boyutu dört farklı açıda (0°, 45°, 90° ve 135°) görüntüye uygulanmıştır. Çizelgede  $i$  satır sayısını,  $j$  sütun sayısını,  $P_{i,j}$  normalleştirilmiş gri-ton konumsal ilişki matrisini,  $\mu$  ve  $\sigma$  ortalama ve standart sapmayı,  $N$  ise görüntüdeki gri düzeylerin sayısını göstermektedir.


**Çizelge 3.10 :** Yardımcı veri seti olarak kullanılan doku özellikleri.

| Doku özelliği | Formül                                                                                        |
|---------------|-----------------------------------------------------------------------------------------------|
| Ortalama      | $\sum_{i,j=0}^{N-1} P_{i,j} / N^2$                                                            |
| Varyans       | $\sigma_{i,j}^2 - \sum_{i,j} P_{i,j} (i, j - \mu_{i,j})$                                      |
| Homojenlik    | $\sum_{i,j=0}^{N-1} P_{i,j} / (1 + (i + j)^2)$                                                |
| Zıtlık        | $\sum_{i,j=0}^{N-1} P_{i,j} / (1 + (i + j)^2)$                                                |
| Farklılık     | $\sum_{i,j=0}^{N-1} P_{i,j}  i - j $                                                          |
| Entropi       | $\sum_{i,j=0}^{N-1} P_{i,j} (-\ln P_{i,j})$                                                   |
| İkinci moment | $\sum_{i,j=0}^{N-1} P_{i,j}^2$                                                                |
| Korelasyon    | $\rho = \sum_{i,j=0}^{N-1} P_{i,j} ((i - \mu_i)(j - \mu_j) / \sqrt{(\sigma_i^2 \sigma_j^2)})$ |

Tez kapsamında ele alınan diğer yardımcı veri seti temel bileşenler analizi ile elde edilen özelliklerdir. Temel bileşenler analizinde amaç değişimi ifade edecek yeni bir koordinat sistemi tanımlamaktır. Ham uydu görüntüsünün temel bileşenler analiziyle yapılan dönüşümü sonucunda, elde edilen yeni görüntünün yorumlanabilirliği orijinal görüntüye göre daha yüksek olmaktadır. Uydu görüntüsüne temel bileşenler analizi uygulanarak WV-2 görüntüsünün 8 spektral bandına karşılık gelen bileşenler hesaplanmıştır. WV-2 görüntüsü kullanılarak gerçekleştirilen temel bileşenler analizi




sonucunda hesaplanan en yüksek varyans değeri (%71,22) Şekil 3.16'dan da görüleceği üzere ilk temel bileşene (TB-1) aittir. Bu durum ilk bileşenin diğer bileşenlere göre görüntü üzerindeki pikseller hakkında daha fazla bilgi içerdiğinin bir göstergesidir. Üçüncü bileşenden sonra varyans değerlerinin çok düşük düzeylerde olduğu görülmektedir. WV-2 görüntüsüne ait ilk üç bileşenin toplamda %98,84 varyansa sahip olduğu görülmüş ve uygulamada söz konusu bileşenler dikkate alınmıştır.



**Şekil 3.16 :** Temel bileşenler analizi sonucunda hesaplanan varyans değerleri.



İlk üç temel bileşen için üretilen haritalara örnek olarak en yüksek varyans değerine sahip olan ilk temel bileşene ait tematik harita Şekil 3.17’de gösterilmiştir. Tematik harita incelendiğinde özellikle bina ve betonarme yapıların yüksek varyans değerlerine sahip olduğu; su ve iğne yapraklı ağaçlara ait değerlerin en düşük düzeyde olduğu görülmektedir.




Şekil 3.17 : Yardımcı veri olarak üretilen ilk temel bileşene ait tematik harita.

Tez kapsamında ele alınan son yardımcı veri seti kırmızı-yeşil-mavi (RGB) renk uzayından ton-doygunluk-yoğunluk (HSI) renk uzayına dönüşüm sonucunda elde edilen bileşenlerdir. Dönüşümün gerçekleştirilmesinde WV-2 görüntüsünün multispektral bantlarının üç farklı kombinasyonu kullanılmıştır. Bunlardan ilki WV-2 görüntüsünün klasik bantlarından (kırmızı (R)-yeşil (G)-mavi (B)) oluşurken, diğer ikisi WV-2’nin kırmızı ve yeşil bantlarıyla birlikte kıızılötesi-1(NIR1) ve kıızılötesi-2 (NIR2) bantlarının kullanıldığı kombinasyonlardır (NIR1-R-G ve NIR2-R-G). Söz



konusu bant kombinasyonları kullanılarak üretilen tematik haritalara örnek olarak Şekil 3.18’de RGB bant kombinasyonu için hesaplanan ton (hue) bileşenine ait tematik harita gösterilmiştir. Harita incelendiğinde en yüksek ton değerlerinin kiremit çatı kaplamasına sahip binalar ve en düşük değerlerin ise canlı bitki örtüsü olarak ifade edilen geniş ve iğne yapraklı türler için hesaplandığı görülmektedir.



Şekil 3.18 : WV-2'nin kırmızı, yeşil ve mavi bantları kullanılarak hesaplanan ton bileşenine ait tematik harita.

### 3.5.2 Arazi örtüsü sınıflarının ve örnekleme alanlarının tespiti

Çalışma alanı mevcut arazi örtüsü ve arazi kullanım sınıfları açısından ele alındığında, genel olarak bölge içerisinde su, toprak, bozkır olarak isimlendirilen temel arazi örtüsü tiplerinin yanında farklı ağaç türlerini içeren orman alanlarının, su geçirmeyen yüzeyler olarak bilinen şehir alanlarının ve bu alanları çevreleyen gölge alanların mevcut olduğu tespit edilmiştir. Söz konusu arazi örtüsü/kullanım sınıfları

kendi içerisinde değerlendirildiğinde orman sınıfı içerisinde çeşitli iğne ve geniş yapraklı ağaç türlerinin mevcut olduğu belirlenmiştir. Saha çalışmaları neticesinde orman sınıfı içerisine dahil edilebilecek 9 farklı ağaç türü tespit edilmiştir. Söz konusu ağaç türlerinden 4'ü iğne yapraklı ve yaprak fenolojisi açısından yaprak dökmeyen ağaç türlerinden iken 5 tanesi geniş yapraklı ve fenolojik açıdan yaprak döken ağaç türlerinden oluşmaktadır. Tez kapsamında arazide gerçekleştirilen spektral ölçümler yardımıyla 9 ağaç türüne ilişkin spektral özellikler belirlenerek spektral kütüphane oluşturulmuştur. Arazideki mevcut ağaç türlerinin dağılımı ve yoğunlukları analiz edildiğinde geniş yapraklı ağaç türlerinden ayva (*Cydonia Oblonga*), karakavak (*Populus nigra L.*) ve ceviz (*Juglans*) ağaçları; iğne yapraklı ağaç türlerinden ise servi (*Cupressus Empervirens*) ağacı için sınıflandırmada kullanılabilecek yoğunlukta, büyüklükte ve sayıda örnekleme alanının bulunmadığı tespit edilmiştir. Bu nedenle orman sınıfını oluşturan ağaç türleri içerisine söz konusu türler dahil edilmemiştir. Orman sınıfına dahil edilen diğer iğne ve geniş yapraklı ağaç türleri Çizelge 3.11'de gösterilmiştir. Söz konusu ağaç türleri için sınıflandırma işlemine esas olacak örnekleme alanlarının tespitinde oluşturulan spektral kütüphaneden yararlanılmış ve spektral eğrilerle ilişkilendirilen WV-2 görüntüsü üzerinden örnekleme alanları belirlenmiştir.

**Çizelge 3.11 : Orman sınıfı içerisine dahil edilen ağaç türleri.**


| Ağaç adı    | Bilimsel Adı           | Familiya    | Tip            | Yaprak Fenolojisi |
|-------------|------------------------|-------------|----------------|-------------------|
| Çınar       | Platanus orientalis L. | Platanaceae | Geniş yapraklı | Yaprak döken      |
| Zeytin      | Olea Europaea          | Oleaceae    | Geniş yapraklı | Yaprak döken      |
| Fıstık Çamı | Pinus Pinea            | Pinaceae    | İğne yapraklı  | Yaprak dökmeyen   |
| Kızılçam    | Pinus Brutia Ten.      | Pinaceae    | İğne yapraklı  | Yaprak dökmeyen   |
| Sedir       | Cedrus                 | Pinaceae    | İğne yapraklı  | Yaprak dökmeyen   |

Spektral kütüphane yardımıyla uydu görüntüsü üzerinden ağaç türlerine ilişkin örnekleme alanlarının belirlenmesinde spektral açı haritalama (SAM) algoritmasından yararlanılmıştır. Bu algoritma referans spektrum (spektral kütüphane) ile görüntüden elde edilen spektrumun karşılaştırılması esasına dayanmaktadır. Her bir spektra  $N$  boyutlu uzayda bir vektör olarak düşünülür ve burada  $N$  görüntüdeki bant sayısına karşılık gelmektedir. Algoritma referans ve görüntü spektralleri arasındaki benzerliği söz konusu iki vektör arasındaki spektral açının hesaplanması yoluyla belirler (Şekil 3.19). SAM sonucu, açının kosinüsü

cinsinden ifade edilerek 0 ile 1 arasında değişen değerler şeklinde oluşturulabilir. Hesaplanan spektral açı yardımıyla görüntüden ve spektral kütüphaneden alınan spektralar hızlıca karşılaştırılabilmektedir. Sonuç görüntü gri renk tonlarında olup koyu renkler daha küçük açı değerlerini yani referans spektrum ile daha iyi eşleşmeyi ifade etmektedir. SAM algoritması bilinmeyen spektrum  $t$  ile referans spektrum  $r$  arasındaki benzerliği (3.8) yardımıyla hesaplamaktadır.

$$\alpha = \cos^{-1} \left( \frac{\sum_{i=1}^{nb} t_i \cdot r_i}{\left( \sum_{i=1}^{nb} t_i^2 \right)^{1/2} \left( \sum_{i=1}^{nb} r_i^2 \right)^{1/2}} \right) \quad (3.8)$$


Eşitlikte,  $\alpha$ , referans ve görüntü spektrumu arasındaki açıyı,  $nb$ , görüntüdeki bant sayısını ifade etmektedir. Seçilen referans spektra ile görüntüdeki piksellere ait spektra arasındaki tüm spektral açılar hesaplanır. Elde edilen sonuç görüntüde referans spektra ile en yüksek benzerliğe sahip pikseller parlak renkle gösterilirken, düşük benzerliğe sahip pikseller koyu renkle gösterilmektedir.



**Şekil 3.19 :** Spektral açı haritalama algoritmasının temel çalışma prensibi.



Tez kapsamında oluşturulan spektral kütüphane kullanılarak SAM algoritması ile WV-2 uydu görüntüsü üzerinden iğne ve geniş yapraklı ağaç türleri için örnekleme alanları tespit edilmiş ve belirlenen örnekleme alanlarının uydu görüntüsü üzerindeki dağılımları Şekil 3.20’de gösterilmiştir.



**Şekil 3.20 :** İğne ve geniş yapraklı ağaç türleri için tespit edilen örnekleme alanları.

Bölgedeki diğer arazi örtüsü/kullanım sınıfları incelendiğinde su geçirimsiz yüzeyler olarak tanımlanan binalar ve yolların çalışma alanı içerisinde mevcut olduğu görülmektedir. Çalışma alanında beyaz, turuncu (kırmızı) ve gri renkli çatıya sahip binalar bulunmaktadır. Söz konusu bina yapılarının her biri ayrı bir sınıf olarak tanımlanmıştır (Çizelge 3.12). Bununla birlikte çalışma alanını çevreleyen ana ve ara yollar tek bir katman olarak ele alınmış ve yol sınıfı içerisine dahil edilmiştir. Çalışma bölgesi içerisinde temel arazi örtüsü olarak toprak, su ve bozkır sınıfları da ayrı bir sınıf olarak tanımlanmıştır. Deniz, dere, havuz ve çalışma bölgesi içerisinde

bulunan atık su toplama tesisindeki su havuzları su sınıfı içerisinde değerlendirmeye alınmıştır. Yüksek konumsal çözünürlüğe sahip uydu görüntüleri yardımıyla arazi örtüsü/kullanımını gösteren tematik harita üretiminde karşılaşılan en büyük problemlerden birisi de gölge sorunudur. Gölge alanları içerisinde kalan pikseller koyu veya gri bina çatıları ve su gibi diğer yeryüzü özellikleri ile benzer spektral özellikler sergileyebilmektedir. Bu nedenle tez çalışmasında gölge probleminden kaynaklanabilecek sınıflandırma hatalarının azaltılması amacıyla gölge sınıfı tanımlanmıştır. Orman sınıfı olarak tanımlanan ve arazide spektral ölçümler yardımıyla örnekleme alanları belirlenen doğal nesneler haricindeki arazi örtüsü/kullanımı sınıfları için örnekleme alanlarının tespitinde farklı tarihlerde çekilmiş hava fotoğrafları, uydu görüntüleri ve arazide el GPS aleti ile belirlenen noktalardan yararlanılmıştır. Tez kapsamında ele alınan tüm arazi örtüsü ve arazi kullanımı sınıfları Çizelge 3.12’de gösterilmiştir.

**Çizelge 3.12 :** Çalışma alanı için belirlenen arazi örtüsü ve arazi kullanım sınıfları.

| Arazi örtüsü ve arazi kullanım sınıfları |                     |              |
|------------------------------------------|---------------------|--------------|
| Temel arazi örtüsü tipleri               |                     | Su           |
|                                          |                     | Bozkır       |
|                                          |                     | Toprak       |
|                                          |                     | Çınar        |
|                                          |                     | Zeytin       |
| Orman                                    | Geniş yapraklı ağaç | Fıstık çamı  |
|                                          | İğne yapraklı ağaç  | Kızılçam     |
|                                          |                     | Sedir        |
|                                          |                     | Bina-kırmızı |
| Su geçirimsiz yüzeyler                   | Şehir               | Bina-gri     |
|                                          |                     | Bina-beyaz   |
|                                          |                     | Yol          |
|                                          |                     | Gölge        |

### 3.6 Özellik Seçimi ve Boyut İndirgeme

WV-2 uydu görüntüsünün sahip olduğu 8 spektral bant ve yardımcı veriler entegre edilerek yüksek boyuta (bant sayısına) sahip veri seti elde edilmiştir. Yüksek sayıda bant veya özelliği içeren veri setinin sınıflandırma işleminde kullanılması durumunda fazlalık ya da yüksek kolerasyona sahip bantlar dikkate alınmakta ve sınıflandırma doğruluğu düşebilmektedir. Bununla birlikte yüksek boyutlu verilerle yapılan sınıflandırma işleminde boyutun artmasına paralel olarak belirli bir noktadan sonra sınıflandırma doğruluğunun düştüğü bilinmektedir. Bu nedenle veri setinin gerek piksel gerekse obje tabanlı sınıflandırması sürecinde hem işlem yükünün azaltılması hem de boyutsallık probleminin önüne geçilerek sınıflandırma doğruluğunun artırılması amacıyla boyut indirgemesi yoluna gidilmiştir. Boyut azaltılması ya da indirgemesi bant seçimi veya özellik çıkarımı olarak bilinen yaklaşımlarla gerçekleştirilmektedir. Boyut azaltılması neticesinde yüksek boyutlu veri setini temsil eden daha düşük boyutlu bir veri seti tanımlanmaktadır. Söz konusu veri seti düşük korelasyona sahip ve arazi örtüsü/kullanım sınıfları arasındaki spektral ayrımın optimum şekilde yapılabilmesine olanak sağlayacak yararlı spektral bilgileri içeren seçilmiş bantlardan oluşmaktadır. Tez kapsamında özellik seçimi amacıyla Çizelge 3.13'te gösterilen filtre ve sarmal tabanlı 13 algoritma kullanılmıştır.

**Çizelge 3.13 : Özellik seçiminde kullanılan algoritmalar.**

| Algoritma                                                        | Kısaltma |
|------------------------------------------------------------------|----------|
| Ki-Kare istatistik testi                                         | ChiSq    |
| Fisher istatistik testi                                          | Fisher   |
| Kazanç oranı                                                     | GainR    |
| Bilgi kazancı                                                    | InfoG    |
| Naive Bayes                                                      | NaiveB   |
| OneR                                                             | OneR     |
| Pearson Korelasyonu                                              | Pearson  |
| Olasılıksal anlamlılık                                           | ProbSig  |
| Relief fonksiyonu                                                | ReliefF  |
| Rastgele orman                                                   | RF       |
| Özyinelemeli özellik eleme esasına dayalı destek vektör makinesi | DVM-ÖÖE  |
| Simetrik belirsizlik                                             | SymtUnc  |
| t-testi                                                          | t-test   |


Hem piksel hem de obje tabanlı sınıflandırma işleminde optimum özellik boyutunun (bant sayısının) tespit edilmesi amacıyla özellik seçimi algoritmaları tarafından belirlenen önem sıralamaları dikkate alınarak farklı boyutlarda veri setleri (örneğin;

obje tabanlı sınıflandırmada en iyi 10, 20, 30, 40, 50, 75, 100, 150 ve 200 özelliği içeren 9 farklı veri seti) oluşturulmuştur. Farklı boyutlarda veri seti oluşturulmasının birkaç önemli nedeni vardır. Bunlardan ilki en yüksek sınıflandırma doğruluğunun elde edildiği optimum bant sayısının tespit edilmesidir. İkinci olarak, tez kapsamında dikkate alınan sınıflandırma algoritmalarının performanslarının artan özellik sayısına göre değişimlerinin analiz edilmesidir. Üçüncü olarak, özellik seçimi algoritmalarının en uygun özelliklerin belirlemesi ve yüksek korelasyona sahip özelliklerin elimine edilmesindeki başarılarının ortaya koyulmasıdır. Son olarak, önerilen yaklaşım yardımıyla uygulamada kullanılan yüksek boyutlu veri seti içerisinde hangi özelliklerin sınıflar arasındaki spektral ayrımın gerçekleştirilmesinde etkili olduğu ve yardımcı verilerin sınıflandırma doğruluğu üzerindeki etkilerinin ortaya koyulmasıdır.



#### 4. OBJE TABANLI SINIFLANDIRMA

Obje tabanlı sınıflandırma işlemi görüntü üzerindeki benzer spektral özelliklere sahip piksellerin gruplandırılarak bu pikselleri temsil eden görüntü objelerinin oluşturulması ve pikseller yerine söz konusu objelerin sınıflandırılması esasına dayanmaktadır. Bu açıdan ele alındığında obje tanımlı sınıflandırma işleminde esas olan görüntü üzerindeki pikseller değil piksellerin bir araya gelmesiyle oluşan görüntü objeleridir. Bu sayede görüntü üzerindeki milyonlarca piksel yerine bunları temsil eden objelerin sınıflandırılması söz konusudur. Obje tabanlı sınıflandırma işleminin gerçekleştirilmesinde takip edilen temel işlem adımları Şekil 4.1’de gösterilmiştir.



**Şekil 4.1 :** Obje tabanlı sınıflandırmada temel işlem adımları.

Benzer spektral özelliklere sahip piksellerin gruplandırılması ve görüntü objelerinin oluşturulması aşaması obje tabanlı sınıflandırma yaklaşımında görüntü segmentasyonu olarak adlandırılmaktadır. Segmentasyon işleminin ardından elde edilen her bir görüntü objesi için objelerin birbirinden ayırt edilmesi amacıyla objelere özgü özellikler tanımlanır. Her bir objenin temsil ettiği piksellere ilişkin ortalama, standart sapma, minimum ve maksimum değerler gibi temel spektral bilgiler özellik olarak tanımlanabileceği gibi gri düzey oluşum matrisi yardımıyla hesaplanan doku özellikleri de objelere ait özellikler olarak tanımlanabilmektedir.


Bununla birlikte obje tabanlı sınıflandırma yaklaşımında sınıflandırmaya konu görüntü objeleri olduğundan objeler arasındaki ilişkiler de (objeler arasındaki komşuluk, yakınlık, obje uzunluğu, obje alanı vb.) özellik olarak değerlendirmeye alınabilmektedir. Segmente edilmiş görüntü üzerindeki objelere ait özelliklerin tanımlanmasının ardından kontrollü sınıflandırma için ön koşul olan eğitim ve test veri setlerinin oluşturulması işlemi gerçekleştirilir. Söz konusu veri setleri önceden belirlenen arazi örtüsü/kullanımı sınıflarını temsil eden objelerden oluşmaktadır. Daha sonra bir kontrollü sınıflandırma algoritması yardımıyla oluşturulan eğitim ve test veri setleri kullanılarak sınıflar arasındaki ayrımın en yüksek doğrulukta gerçekleştirildiği sınıflandırma modeli üretilir. Test veri seti ile performansı belirlenen model, hangi sınıfa ait olduğu bilinmeyen diğer görüntü objelerinin sınıflandırılmasında kullanılır. Sınıflandırma sonucunda, obje tabanlı yaklaşımla üretilen segmentlerin (görüntü objelerinin) önceden belirlenen bir arazi örtüsü/kullanımı sınıfına atandığı tematik harita üretilir.

#### **4.1 Görüntü Segmentasyonu**

Tez kapsamında WV-2 uydu görüntüsü ve yardımcı verileri içeren veri setinin segmente edilmesinde çoklu çözünürlük segmentasyonu algoritması kullanılmıştır. Algoritma ile segmentasyon işleminin gerçekleştirilmesinde klasik yaklaşım olarak bilinen tüm görüntü için tek bir ölçek parametresi kullanımı yerine, görüntüdeki doğal ve yapay nesneler göz önüne alınarak görüntünün bölgelere ayrılması ve her bir bölge için ayrı bir ölçek parametresi belirlenmesi yaklaşımı önerilmiştir. Önerilen yaklaşımın geçerliliğini test etmek amacıyla, öncelikli olarak tüm görüntü için optimum ölçek parametresi 50 seçilerek segmentasyon işlemi yapılmıştır. Klasik yaklaşımla gerçekleştirilen çoklu segmentasyon işlemi sonucunda 377.190 görüntü objesi elde edilmiştir.

Tez kapsamında önerilen segmentasyon yaklaşımının uygulanması amacıyla çalışma bölgesi önce Şekil 4.2’de gösterildiği üzere 6 farklı bölgeye ayrılmış ve her bir bölge kendi içerisinde değerlendirilerek bölgelere özgü ölçek parametreleri tespit edilmiştir. Şekilde Bölge-1, 3 ve 5 olarak tanımlanan alanlar için en uygun ölçek parametresi 50 olarak belirlenmiştir. Bunun temel nedeni söz konusu bölgeler içerisinde diğer doğal ve yapay nesnelere kıyasla daha küçük bir kanopiye sahip olan zeytin (Bölge-1) ve genç fıstık çamı (Bölge-3 ve 5) ağaçlarının bulunduğu

görülmektedir. Söz konusu ağaç türlerini en uygun şekilde ifade edecek görüntü objelerinin oluşturulmasında ölçek parametresinin 50 olduğu tespit edilmiştir. Bu değerin altındaki seçimlerde zeytin ve fıstık çamı kanopilerinden çok daha küçük objeler oluşurken, daha büyük değerler için ağaçların gölgesinin ve etrafındaki bozkır alanlarının obje içerisine dahil edildiği görülmüştür.



**Şekil 4.2 :** Farklı ölçek parametrelerinin belirlendiği bölgeler.

Şekilde Bölge-2 olarak adlandırılan kısımda olgun fıstık çamları ve kızılçamların bir arada bulunduğu yoğun bir orman örtüsü mevcuttur. Bu bölge için ölçek parametresi 70 seçilmesi ile söz konusu ağaç türlerini temsil edebilen ideal görüntü objeleri belirlenmiştir. Ölçek parametresi olarak bu bölge için daha yüksek değerler seçildiğinde obje içerisinde ağaç kanopisi ile beraber ağaçlara ait gölge alanlarının da dahil edildiği görülmüştür. Görüntü üzerinde diğer bölgelere göre en yüksek ölçek parametresinin seçildiği alanlar 4. ve 6. bölgedir. Bölge-4 içerisinde su geçirimsiz

yüzey olarak tanımlanan bina ve beton yapılar mevcuttur. Bununla birlikte çalışma alanında su sınıfı içerisine dahil edilen deniz, dere, havuz ve arıtma tesisi içerisindeki havuz alanları bulunmaktadır. Bölge-6 içerisinde ise yoğun bozkır ve toprak örtüsü bulunmaktadır. Küçük değerler seçildiğinde aynı arazi örtüsü sınıfını gösteren obje çok fazla parçaya bölünmekte ve değerlendirmeye alınacak obje sayısı artmaktadır.

Bölgelere göre tespit edilen ve Çizelge 4.1’de gösterilen ölçek parametreleri kullanılarak çoklu segmentasyon algoritması ile her bölge ayrı ayrı segmente edilmiştir. Daha sonra segmente edilen her bir bölge birbiriyle entegre edilip birleştirilerek tek bir görüntü elde edilmiştir. Elde edilen entegre görüntüde toplam 250.850 görüntü objesi bulunmaktadır. Farklı ölçek parametreleri ile segmentasyon yaklaşımı sonucunda üretilen obje sayısı, tek ölçek parametresi kullanılarak elde edilen obje sayısından %34 daha azdır. Diğer bir ifadeyle farklı ölçek yaklaşımı ile daha az görüntü objesi üretildiğinden sınıflandırma için gereken işlem zamanı daha az olacaktır.

**Çizelge 4.1 :** Çoklu çözünürlük segmentasyonu işleminde kullanılan parametre değerleri ve obje sayıları.

|          | Ölçek | Şekil | Yoğunluk | Obje Sayısı | Piksel Sayısı |
|----------|-------|-------|----------|-------------|---------------|
| Bölge -1 | 50    | 0,3   | 0,8      | 47.160      | 1.750.986     |
| Bölge -2 | 70    | 0,3   | 0,8      | 84.403      | 5.320.224     |
| Bölge -3 | 50    | 0,3   | 0,8      | 48.549      | 1.430.338     |
| Bölge -4 | 90    | 0,3   | 0,8      | 18.060      | 1.365.004     |
| Bölge -5 | 50    | 0,3   | 0,8      | 31.835      | 932.400       |
| Bölge -6 | 100   | 0,3   | 0,8      | 20.843      | 2.582.748     |
|          |       |       | Toplam   | 250.850     | 13.381.700    |

Klasik ve önerilen segmentasyon yaklaşımıyla görüntünün segmente edilmesinin ardından, her iki görüntü üzerindeki objeler için aynı temel özellikler (ortalama, standart sapma, minimum ve maksimum piksel değerleri) tanımlanarak sınıflandırma işlemi gerçekleştirilmiştir. Objelerin sınıflandırılmasında destek vektör makineleri ve en yakın komşuluk algoritmaları kullanılmıştır. Elde edilen sınıflandırma doğruluklarının karşılaştırılmasında objektifliği sağlamak amacıyla aynı test veri seti kullanılmış ve test veri seti için elde genel sınıflandırma doğrulukları Çizelge 4.2’de gösterilmiştir. Çizelgeden de görüleceği üzere önerilen yaklaşımla destek vektör makineleriyle %6, en yakın komşuluk algoritmasıyla %3 daha yüksek sınıflandırma doğruluğu elde edilmiştir. Ulaşılan bu sonuç obje tabanlı sınıflandırma işleminde görüntü üzerindeki objelere göre farklı ölçek parametresi seçilmesi yaklaşımının

geçerliliğini destekler niteliktedir. Bu nedenle tez kapsamında obje tabanlı sınıflandırma işleminin gerçekleştirilmesinde önerilen farklı ölçek parametreleri yaklaşımı kullanılmıştır. Bu yaklaşımdan yola çıkılarak tespit edilen ölçek parametreleri kullanılarak çoklu çözünürlük segmentasyonu gerçekleştirilmiş ve sınıflandırmaya esas görüntü objeleri oluşturulmuştur.

**Çizelge 4.2 :** Tek ölçek ve farklı ölçek parametreleri kullanılarak elde edilen genel sınıflandırma doğrulukları.

| Sınıflandırma Yöntemi         | Tek ölçek parametresi (%) | Farklı ölçek parametreleri (%) | Doğruluk farkı (%) |
|-------------------------------|---------------------------|--------------------------------|--------------------|
| Destek vektör makineleri      | 85,86                     | 91,78                          | 5,92               |
| En yakın komşuluk algoritması | 80,82                     | 83,76                          | 2,94               |

#### 4.2 Görüntü Objelerine Ait Özelliklerin Tanımlanması

Tez kapsamında önerilen yaklaşımla elde edilen görüntü objelerine ait tanımlanan özellikler Çizelge 4.3’de gösterilmiştir. Söz konusu özelliklerin seçiminde literatürde en sık dikkate alınanlar tercih edilmiştir. Her bir görüntü objesi için tablodaki özelliklerin tanımlanmasıyla obje tabanlı sınıflandırma işlemine esas olan ve 216 özelliği (bandı) içeren çok boyutlu veri seti elde edilmiştir.

**Çizelge 4.3 :** Obje tabanlı sınıflandırma işleminde dikkate alınan özellikler.

| Özellik                 | Açıklama                                                                     |
|-------------------------|------------------------------------------------------------------------------|
| Temel spektral bilgiler | Ortalama WV-2 bantları, ilk üç temel bileşen ve vejetasyon indeksleri        |
|                         | Standart Sapma WV-2 bantları, ilk üç temel bileşen ve vejetasyon indeksleri  |
|                         | Minimum piksel WV-2 bantları, ilk üç temel bileşen ve vejetasyon indeksleri  |
|                         | Maksimum piksel WV-2 bantları, ilk üç temel bileşen ve vejetasyon indeksleri |
|                         | Maksimum fark WV-2 bantları                                                  |
|                         | Oran WV-2 bantları                                                           |
|                         | Parlaklık WV-2 bantları                                                      |
|                         | Ton WV-2 (R-G-B; NIR1-R-G; NIR2-R-G)                                         |
|                         | Doygunluk WV-2 (R-G-B; NIR1-R-G; NIR2-R-G)                                   |
|                         | Yoğunluk WV-2 (R-G-B; NIR1-R-G; NIR2-R-G)                                    |
| Doku özellikleri        | Ortalama WV-2 (Tüm yönlerde GLCM; 0°, 45°, 90°, 135°)                        |
|                         | Varyans WV-2 (Tüm yönlerde GLCM; 0°, 45°, 90°, 135°)                         |
|                         | Homojenlik WV-2 (Tüm yönlerde GLCM; 0°, 45°, 90°, 135°)                      |
|                         | Zıtlık WV-2 (Tüm yönlerde GLCM; 0°, 45°, 90°, 135°)                          |
|                         | Farklılık WV-2 (Tüm yönlerde GLCM; 0°, 45°, 90°, 135°)                       |
|                         | Entropi WV-2 (Tüm yönlerde GLCM; 0°, 45°, 90°, 135°)                         |
|                         | İkinci moment WV-2 (Tüm yönlerde GLCM; 0°, 45°, 90°, 135°)                   |
|                         | Korelasyon WV-2 (Tüm yönlerde GLCM; 0°, 45°, 90°, 135°)                      |

### 4.3 Eğitim ve Test Veri Setlerinin Oluşturulması

Segmente edilen ve objelere ait özellikleri tanımlanan görüntü üzerinden sınıflandırmaya esas olacak eğitim ve test alanları belirlenmiştir. Söz konusu alanlar orman sınıfındaki ağaç türleri için spektral ölçüler yardımıyla belirlenen örnek alanlar içerisinde tespit edilirken, diğer arazi örtüsü sınıfları için mevcut harita ve uydu görüntüleri üzerinden belirlenmiştir. Objektif analizlerin yapılabilmesi ve kullanılacak veri setlerinin birbirinden bağımsız (korelasyonsuz) olmasının sağlanması amacıyla eğitim ve test alanları farklı bölgelerden seçilmiştir. Çizelge 4.4'den de görüleceği üzere 13 arazi örtüsü ve arazi kullanım sınıfını temsil eden eğitim verisi olarak toplam 501, test verisi olarak toplam 146 görüntü objesi belirlenmiştir.


**Çizelge 4.4 :** Sınıflandırmaya esas eğitim ve test verilerini oluşturan objelerin arazi örtüsü/kullanımı sınıflarına göre dağılımı.

| Sınıf adı    | Eğitimde kullanılan obje sayısı | Testte kullanılan obje sayısı |
|--------------|---------------------------------|-------------------------------|
| Fıstık Çamı  | 55                              | 13                            |
| Kızıl Çam    | 42                              | 12                            |
| Sedir        | 30                              | 12                            |
| Çınar        | 30                              | 11                            |
| Zeytin       | 46                              | 11                            |
| Su           | 13                              | 10                            |
| Bozkır       | 46                              | 11                            |
| Toprak       | 51                              | 12                            |
| Bina-Kırmızı | 46                              | 10                            |
| Bina-Gri     | 30                              | 10                            |
| Bina-Beyaz   | 35                              | 11                            |
| Yol          | 37                              | 12                            |
| Gölge        | 40                              | 11                            |

### 4.4 Özellik (Bant) Seçimi ve Boyut İndirgeme

Segmentasyon sonucunda elde edilen objeler için tanımlanan 216 farklı özellik içerisinde sınıflar arasındaki ayrımın en etkili şekilde gerçekleştirilmesine olanak sağlayan özelliklerin tespit edilmesi ve yüksek boyutlu veri içerisinde gereksiz/faydasız bilgi içeren bantların elenerek boyut indirgemesi amacıyla özellik seçimi yoluna gidilmiştir. Bu amaca yönelik takip edilen işlem adımları Şekil 4.3'de gösterilmiştir. Özellik seçiminin gerçekleştirilmesinde 13 farklı algoritma değerlendirmeye alınmıştır. Optimum özellik boyutunun tespit edilmesi amacıyla söz


konusu algoritmalar tarafından belirlenen sıralamalar dikkate alınarak en iyi 10, 20, 30, 40, 50, 75, 100, 150 ve 200 özelliği içerecek şekilde 9 farklı veri seti oluşturulmuştur. Her bir özellik seçimi algoritması için ayrı ayrı oluşturulan farklı boyutlardaki veri setleri sınıflandırma işlemine tabi tutularak özellik boyutundaki artışın sınıflandırma doğruluğuna olan etkileri incelenmiş ve önerilen özellik seçimi algoritmalarının performansı analiz edilmiştir.



**Şekil 4.3 :** Özellik seçimi işleminde takip edilen işlem adımları.

Özellik seçimi sonucunda 117 farklı eğitim ve test veri seti (13 özellik seçimi algoritması sonuçlarına göre üretilen 9 farklı veri seti) sınıflandırma işlemine tabi tutulmuştur. Söz konusu veri setlerinin sınıflandırılmasında literatürde piksel tabanlı sınıflandırma uygulamalarında etkinliği ortaya koyulan ancak obje tabanlı sınıflandırma uygulamalarında son birkaç yıldır kullanılmaya başlayan 7 farklı makine öğrenme algoritması (karar ağaçları, destek vektör makineleri, rastgele orman, torbalama, hızlandırma, çoklu hızlandırma ve rotasyon orman) kullanılmıştır. Bunun yanı sıra önerilen makine öğrenme algoritmalarının performanslarının karşılaştırılması amacıyla obje tabanlı sınıflandırma yaklaşımında klasik

sınıflandırıcı olarak kabul edilen en yakın komşuluk algoritması da değerlendirmeye alınmıştır. Tez kapsamında önerilen özellik seçimi yaklaşımının çalışma prensibi Şekil 4.4’te bir örnek üzerinde gösterilmiştir. Örnekte ki-kare istatistiği yardımıyla seçilen özelliklerin en yakın komşuluk algoritması ile sınıflandırıldığı senaryo temsil edilmiştir. Ki-kare istatistiği ile 216 özelliğe sahip veri setinin her özelliği için bir istatistik değer veya puan belirlenir. Hesaplanan puanlamalara göre bantlar en yüksekten en düşüğe göre sıralanır. Daha sonra en uygun bant sayısını belirlemek amacıyla hesaplanan sıralamalar dikkate alınarak en iyi 10, 20, 30, 40, 50, 75, 100, 150 ve 200 bandı içerecek şekilde 9 farklı veri seti oluşturulur. Son olarak oluşturulan her bir veri seti için en yakın komşuluk algoritmasının sınıflandırma performansı analiz edilir.



**Şekil 4.4 : Özellik seçimi ile ilgili önerilen yaklaşım.**

#### 4.5 Obje Tabanlı Sınıflandırma İçin Performans Analizi

Özellik seçimi sonucunda oluşturulan veri setleri kullanılarak tezde dikkate alınan 8 sınıflandırma yönteminin performansı ayrı ayrı analiz edilmiştir. Analiz sonucunda her bir sınıflandırıcı için en yüksek sınıflandırma doğruluğunun elde edildiği veri seti ve optimum veri seti boyutu belirlenmiştir. Bununla birlikte, elde edilen sınıflandırma performanslarının karşılaştırılması neticesinde en yüksek sınıflandırma performansı gösteren algoritma tespit edilmiştir. Analizlerde öncelikli olarak her bir algoritmanın sınıflandırma performansı özellik seçimi algoritmalarınca belirlenen farklı boyutlarda veri setleri dikkate alınarak kendi içerisinde ayrıntılı olarak incelenmiştir. Daha sonra elde edilen sonuçlar karşılaştırılmıştır. Örneğin en yakın komşuluk (EYK) algoritması için ilk olarak en iyi 10 bandı içeren veri setleri kullanılarak sınıflandırma performansı analiz edilmiş ve 10 boyutlu veri setleri




içerinde en yüksek sınıflandırma doğruluğunun elde edildiği veri seti belirlenmiştir. Bu yaklaşımla sırasıyla 20, 30, 40, 50, 75, 100, 150 ve 200 bandı içeren veri setleri için de EYK'nın sınıflandırma performansı analiz edilmiştir. Bu işlem adımları tez kapsamında dikkate alınan tüm sınıflandırma algoritmaları için ayrı ayrı uygulanarak obje tabanlı sınıflandırma işleminin gerçekleştirilmesinde en etkili özellik seçimi algoritması, spektral ayırım için en uygun bantlar, optimum bant sayısı ve en yüksek sınıflandırma performansının elde edildiği sınıflandırma algoritması belirlenmiştir.


#### **4.5.1 En yakın komşuluk algoritması ile obje tabanlı sınıflandırma**

Özellik seçimi algoritmalarının belirlediği bant sıralamaları dikkate alınarak oluşturulan 9 farklı boyutta veri setleri için en yakın komşuluk (EYK) algoritmasının sınıflandırma performansı Şekil 4.5'te gösterilmiştir. Şekilde 13 özellik seçimi algoritmaları tarafından belirlenen en iyi ilk 10 bandı içeren veri setleri için EYK algoritmasının sınıflandırma performansı analiz edildiğinde, en yüksek sınıflandırma doğruluğunun bilgi kazancı (InfoG) algoritması tarafından belirlenen veri seti için %87,67 olarak hesaplandığı görülmektedir. 20 ve 30 bantlı veri setleri EYK ile sınıflandırıldığında, en yüksek sınıflandırma doğruluklarının rastgele orman (RF) algoritmasıyla belirlenen bantlarla elde edildiği görülmektedir. Bu veri setleri için hesaplanan en yüksek doğruluk değeri %86,30 olup, bant sayısının 20'den 30'a çıkmasıyla EYK algoritmasının performansında herhangi bir değişiklik olmadığı görülmüştür. Diğer taraftan şekilde EYK algoritmasının 10, 20 ve 30 bantlı veri setleri içerisinde en düşük sınıflandırma doğruluklarına DVM-ÖÖE tarafından belirlenen veri setleri kullanımıyla ulaştığı görülmektedir.


En iyi 40 bandı içeren veri setlerinin EYK ile sınıflandırılması sonucunda elde edilen genel sınıflandırma doğrulukları incelendiğinde, en yüksek sınıflandırma doğruluğunun (%87,67) OneR algoritması tarafından seçilen veri seti ile elde edildiği, en düşük doğruluğun ise (%56,85) Pearson korelasyonu (Pearson) algoritmasına ait veri seti için hesaplandığı görülmektedir. 50 ve 75 bantlı veri setleri arasında EYK en yüksek sınıflandırma doğruluklarına t-test algoritmasının seçtiği özelliklerle ulaşmıştır. Özellikle 75 bantlı veri setleri için hesaplanan sınıflandırma doğrulukları incelendiğinde, t-test haricindeki diğer veri setlerinin boyutu 50'den 75'e çıkmasıyla EYK algoritmasının performansında %4'e varan seviyelerde düşüş yaşandığı görülmüştür.




10 bantlı veri setleri




20 bantlı veri setleri




30 bantlı veri setleri




40 bantlı veri setleri




50 bantlı veri setleri




75 bantlı veri setleri



100 bantlı veri setleri



150 bantlı veri setleri



200 bantlı veri setleri


**Şekil 4.5 :** Obje tabanlı yaklaşımda farklı boyutta veri setleri için EYK algoritmasının sınıflandırma performansı.

Veri seti boyutu 100'e çıkarıldığında EYK algoritmasının sergilediği sınıflandırma performansı analiz edildiğinde, şekilden de görüleceği üzere veri seti boyutunun artması ile birlikte üç farklı veri seti (Fisher, NaiveB ve Pearson) ile aynı sınıflandırma doğruluğuna (%77,40) ulaşılmıştır. Diğer veri setleri için hesaplanan doğrulukların %77 düzeyinde olduğu görülmektedir.


EYK algoritmasının sınıflandırma performansı özellik seçimi sonucunda oluşturulan 150 bantlı veri setleri açısından ele alındığında, NaiveB algoritması tarafından seçilen veri seti ile en yüksek sınıflandırma doğruluğuna (%78.08) ulaşıldığı, diğer veri setleri için hesaplanan doğruluklar ise %76 düzeyinde olduğu görülmüştür (Şekil 3.25). Aynı şekilde, 200 bantlı veri setleri içerisinde en yüksek doğruluğun elde edildiği Fisher ve Pearson veri setleri haricindeki diğer verilerle ulaşılabilen doğrulukların %76 seviyelerindedir.

#### **4.5.2 Karar ağaçları algoritması ile obje tabanlı sınıflandırma**


Tez kapsamında segmente edilmiş görüntünün karar ağaçları (KA) ile sınıflandırılması işlemi tek değişkenli karar ağacı algoritmalarından C4.5 algoritması ile gerçekleştirilmiştir. Karar ağacı oluşumunda dallanmaya esas olacak özelliklerin seçiminde kazanç oranı kriteri kullanılmıştır. KA ile farklı boyutta ve farklı özellik seçimi algoritmaları tarafından oluşturulan veri setleri ayrı ayrı değerlendirilmiş ve elde edilen sınıflandırma doğrulukları Şekil 4.6'da gösterilmiştir. Şekil incelendiğinde 10, 30 ve 150 bantlı veri setleri içerisinde NaiveB algoritması, 20 ve 200 bantlı veri setleri içerisinde ise olasılıksal anlamlılık (ProbSign) algoritması tarafından oluşturulan veri setleri ile en yüksek sınıflandırma doğruluğuna ulaşıldığı görülmektedir. En iyi 50 bantı içeren veri setleri KA ile sınıflandırıldığında OneR ve simetrik belirsizlik (SymtUnc) algoritmalarının seçtiği bant kombinasyonlarıyla aynı sınıflandırma doğruluğu elde edilmiştir. Bununla birlikte 40 bantlı veri setleri içerisinde OneR olarak adlandırılan veri seti ile en yüksek doğruluğa ulaşılrken, 100 bantlı veri setleri içerisinde ise Fisher testinin belirlediği bantlar ile KA yüksek sınıflandırma performansı sergilemiştir. En iyi 75 bantı içeren veri setleri KA ile sınıflandırıldığında ise Şekil 3.26'den de görüleceği üzere DVM-ÖÖE algoritmasının belirlediği veri setiyle %3 daha yüksek sınıflandırma doğruluğuna ulaşılmıştır. Bu noktada diğer algoritmaların seçtiği veri setleri için hesaplanan doğruluklar %78 seviyelerindedir.




10 bantlı veri setleri




20 bantlı veri setleri




30 bantlı veri setleri




40 bantlı veri setleri




50 bantlı veri setleri




75 bantlı veri setleri



100 bantlı veri setleri



150 bantlı veri setleri



200 bantlı veri setleri


**Şekil 4.6 :** Obje tabanlı yaklaşımda farklı boyutta veri setleri için KA algoritmasının sınıflandırma performansı.

Şekil 4.6 incelendiğinde küçük veri seti boyutu söz konusu olduğunda Pearson ve Relief (ReliefF) fonksiyonları ile seçilen özellikler ile en düşük sınıflandırma doğruluklarının elde edildiği görülmektedir. KA sınıflandırıcısı kullanılan bant sayısı 10, 40 ve 50 olduğu durumlarda Pearson; 20 ve 30 olduğunda ise ReliefF algoritmalarının seçtiği veri setleri ile düşük performans ortaya koymuştur. Diğer taraftan veri seti boyutunun artmasıyla (75, 100 ve 150 bant) t-testi ile belirlenen özelliklerle KA en düşük sınıflandırma sonuçlarını üretmiştir.


#### **4.5.3 Destek vektör makineleri ile obje tabanlı sınıflandırma**

Tez kapsamında segmente edilmiş görüntünün destek vektör makineleri (DVM) ile sınıflandırılmasında radyal tabanlı kernel fonksiyonundan yararlanılmıştır. DVM ile sınıflandırma işleminde kullanıcı tarafından belirlenmesi gereken parametreler mevcuttur. Söz konusu parametreler düzenleme parametresi (C) ve radyal tabanlı kernel için kernel genişliği ( $\gamma$ )'dir. Söz konusu parametre değerleri değerlendirmeye alınan her farklı veri seti için ayrı ayrı belirlenmiş (Çizelge A.1) ve analizlerde tespit edilen optimum parametreler kullanılarak elde edilen sınıflandırma doğrulukları Şekil 4.7'de gösterilmiştir.


Şekil incelendiğinde değerlendirmeye alınan 9 farklı veri seti boyutu içerisinde DVM ile hesaplanan en yüksek sınıflandırma doğruluklarının küçük veri seti boyutlarında (30, 40 ve 50 bant) elde edildiği ve bu sonuçlara özyinelemeli özellik seçimi esasına dayalı destek vektör makineleri (DVM-ÖÖE) algoritmasının belirlediği bant kombinasyonları ile ulaşıldığı görülmektedir. Şekilden de görüleceği üzere 75 banttan sonra veri setine eklenecek bantlar DVM algoritmasının sınıflandırma doğruluğunu önemli derecede arttırmadığı görülmektedir. Nitekim 100 bantlı veri setleri içerisinde NaviB, Pearson ve DVM-ÖÖE veri setleri ile aynı sınıflandırma doğruluğuna ulaşılırken, 150 bant göz önüne alındığında ise NavieB, Pearson ve t-test ile en yüksek sınıflandırma sonuçları elde edilmiştir. Elde edilen sonuçlar veri seti boyutunun 100'den 150'ye çıkarılmasının DVM algoritmasının performansında anlamlı bir değişiklik olamadığını göstermektedir. Özellikle toplam veri setinin %93'nü kapsayan 200 bantlı veri setleri için elde edilen sonuçlar göz önüne alındığında, özellik seçiminde kullanılacak algoritmanın önemsiz hale geldiği ve değerlendirmeye alınan 13 özellik seçimi algoritmasından 7'si için DVM için aynı sınıflandırma doğruluğuna ulaştığı ifade edilebilir.




10 bantlı veri setleri




20 bantlı veri setleri




30 bantlı veri setleri




40 bantlı veri setleri




50 bantlı veri setleri




75 bantlı veri setleri



100 bantlı veri setleri



150 bantlı veri setleri



200 bantlı veri setleri


**Şekil 4.7 :** Obje tabanlı yaklaşımda farklı boyutta veri setleri için DVM algoritmasının sınıflandırma performansı.

Şekilden de görüleceği üzere 75 banda kadar DVM için hesaplanan en düşük sınıflandırma doğruluklarına OneR, Relief ve t-test algoritmalarının belirlediği özellikler ile ulaşılmıştır. Bu noktadan sonra DVM algoritması yüksek boyutlu veri setleri için benzer performans sergileyerek, aynı boyutta birkaç veri seti ile aynı sınıflandırma doğruluğuna ulaşmıştır. Örneğin 100 bant için en düşük sınıflandırma doğruluğu GainR ve t-test verileri için hesaplanırken, 150 bantta ki-kare (ChiSq), OneR, Relief, RF ve DVM-ÖÖE veri setleri ile elde edilmiştir.


#### **4.5.4 Rastgele orman sınıflandırıcısı ile obje tabanlı sınıflandırma**

Rastgele orman (RO) algoritması birçok karar ağacının birleşiminden oluşan ve her bir ağacın tahminlerinden yola çıkarak sınıflandırma işlemini gerçekleştiren bir algoritmadır. RO algoritmasında ağaç oluşumu için her bir düğümde kullanılan özelliklerin sayısı ve ağaç sayısı kullanıcı tarafından belirlenmesi gereken parametrelerdir. Söz konusu parametre değerleri değerlendirmeye alınan her veri seti için ayrı ayrı belirlenmiş ve analizlerde tespit edilen optimum parametreler kullanılarak elde edilen sınıflandırma doğrulukları Şekil 4.8’de gösterilmiştir.


Şekil incelendiğinde RO algoritmasının NaiveB (10 ve 200 bant), RF (20 ve 30 bant), DVM-ÖÖE (40 ve 75 bant), t-test (100 bant) ve ReliefF (150) algoritmalarının seçtiği özelliklerle en yüksek sınıflandırma doğruluklarına ulaştığı görülmektedir. Bununla birlikte, RO sınıflandırıcısının 50 bantlı veri setleri içerisinde GainR ve DVM-ÖÖE algoritmalarının belirlediği bant kombinasyonları ile en yüksek sınıflandırma doğruluğuna ulaştığı görülmektedir. Diğer taraftan, 10, 20, 30 ve 40 banda sahip küçük boyutlu veri setleri içerisinde en düşük sınıflandırma doğrulukları Pearson ve Relief algoritmaları tarafından seçilen özellikler ile elde edilmiştir. 50 ve 75 bantlı veri setleri arasında en düşük sınıflandırma doğrulukları SyntUnc algoritmasına ait veri setiyle elde edilirken, bu noktadan sonra elde edilen sınıflandırma doğrulukları arasındaki fark azalmakta ve farklı veri setleri için benzer doğruluklar elde edilmiştir. Şekilde verilen sınıflandırma sonuçları bir bütün olarak ele alındığında, RO algoritmasının seçilen 75 ve üzeri bantlar için %91’in üzerinde sınıflandırma doğruluğu elde ettiği, düşük veri seti boyutları için hesaplanan doğrulukların %90’ın altında olduğu görülmektedir. RO algoritması için hesaplanan en yüksek doğruluk DVM-ÖÖE algoritmasının seçtiği 75 özelliği içeren veri seti ile elde edildiği tespit edilmiştir.




10 bantlı veri setleri




20 bantlı veri setleri




30 bantlı veri setleri




40 bantlı veri setleri




50 bantlı veri setleri




75 bantlı veri setleri



100 bantlı veri setleri



150 bantlı veri setleri



200 bantlı veri setleri

**Şekil 4.8 :** Obje tabanlı yaklaşımda farklı boyutta veri setleri için RO algoritmasının sınıflandırma performansı.




#### 4.5.5 Torbalama algoritması ile obje tabanlı sınıflandırma


Torbalama algoritması karar ağacını esas alan bir sınıflandırma algoritmasıdır. Algoritmanın çalışma prensibi kullanılan eğitim setinin rastgele bir şekilde yeniden oluşturulması ve her bir veri setinin karar ağaçları ile sınıflandırılması esasına dayanmaktadır. Algoritmanın kullanımında torba boyutu ve iterasyon sayısı olarak bilinen iki parametrenin kullanıcı tarafından belirlenmesi gerekmektedir. Söz konusu parametre değerleri değerlendirmeye alınan her farklı veri seti için ayrı ayrı belirlenmiş ve analizlerde tespit edilen optimum parametreler kullanılmıştır (Çizelge A.2).

Torbalama algoritması (TRB) ile farklı özellik seçimi algoritmaları tarafından oluşturulan farklı boyutta veri setleri ayrı ayrı değerlendirilmiş ve elde edilen sınıflandırma doğrulukları Şekil 4.9'da gösterilmiştir. Şekil incelendiğinde TRB algoritmasının 20, 30 ve 40 bantlı veri setleri ile %88 düzeyinde, diğer veri seti boyutlarında ise algoritmanın sınıflandırma performansının yaklaşık %86 seviyelerinde olduğu görülmektedir. Elde edilen yüksek doğruluk değerlerine OneR ve ProbSign algoritmaları tarafından seçilen özellikler kullanılarak ulaşılmıştır. Diğer taraftan küçük boyutlu veri setleri içerisinde (10, 20, 30, 40, 50 ve 75 bant) TRB algoritması en düşük sınıflandırma performanslarını Pearson ve Relief algoritmaları tarafından seçilen özellikler kullanımıyla elde ettiği şekilden de görülmektedir.


TRB algoritmasının performansı incelendiğinde, 75 bantlı veri seti kullanımına kadar elde edilen sonuçlar arasında büyük farklılıklar olduğu bu kritik veri seti boyutundan sonra farklı veri setleri kullanımıyla benzer sınıflandırma sonuçlarına ulaşıldığı görülmektedir. Özellikle 200 bantlı veri setleri için elde edilen sonuçlardan da görüleceği üzere ReliefF algoritmasının belirlediği dışındaki diğer veri setleri için TRB algoritmasının ürettiği sınıflandırma doğrulukları %84 düzeyindedir. Diğer bir ifadeyle 200 bantlı veri seti kullanımında özellik seçiminde kullanılacak algoritmanın önemsiz hale geldiği ve nerdeyse tüm veri setleri için aynı sınıflandırma performansının elde edildiğini ifade edilebilir.




10 bantlı veri setleri




20 bantlı veri setleri




30 bantlı veri setleri




40 bantlı veri setleri




50 bantlı veri setleri




75 bantlı veri setleri



100 bantlı veri setleri



150 bantlı veri setleri



200 bantlı veri setleri


**Şekil 4.9 :** Obje tabanlı yaklaşımda farklı boyutta veri setleri için TRB algoritmasının sınıflandırma performansı.

#### 4.5.6 Hızlandırma algoritması ile obje tabanlı sınıflandırma


Hızlandırma algoritması (HIZ) karar ağacı sınıflandırıcısının performansının artırılmasında kullanılan bir algoritmadır. Algoritmanın kullanımında iterasyon sayısı olarak bilinen parametrenin kullanıcı tarafından belirlenmesi gerekmektedir. Söz konusu parametre için optimum değer kullanılan her farklı veri seti için ayrı ayrı belirlenmiş (Çizelge A.2) ve elde edilen sınıflandırma sonuçları Şekil 4.10'da gösterilmiştir.

Özellik seçimi ile belirlenen 10 ve 20 bantlı veri setleri için elde edilen sınıflandırma doğrulukları analiz edildiğinde, OneR algoritmasının belirlediği veri setleri ile HIZ algoritmasının en yüksek sınıflandırma doğruluğuna ulaştığı görülmektedir. Bu noktada OneR algoritmasının belirlediği 10 bantlı veri setine 10 bandın daha ilave edilmesiyle HIZ algoritmasının sınıflandırma performansının yaklaşık %3 seviyelerinde arttığı görülmektedir. Bu veri seti boyutunda en düşük doğruluklar Pearson ve ReliefF veri setleri elde edilmiştir. Elde edilen doğruluklar 10 bantlı veri seti için hesaplanan en yüksek değerden %15 ve 20 bantlı veri seti için hesaplanan en yüksek değerden %8 daha düşüktür. 30 bantlı veri setleri içerisinde en yüksek doğruluk NaiveB algoritmasına ait veri seti ile elde edilirken, ReliefF veri seti ile HIZ algoritması en düşük performansını sergilediği görülmektedir. HIZ algoritması 40 ve 75 bantlı veri setleri arasında DVM-ÖÖE ile belirlenen özelliklerle en iyi sınıflandırma performansına ulaşırken, 50 bantlı veri setleri içerisinde SymtUnc algoritmasının seçtiği özelliklerle en yüksek doğruluğa ulaşmıştır.


Şekilden de görüleceği üzere elde edilen tüm sınıflandırma performansları bir arada değerlendirildiğinde HIZ algoritmasının sadece Fisher ve ReliefF algoritmalarının seçtiği 100 bantlı veri setleri ile %90'ın üzerinde sınıflandırma doğruluğu elde ettiği diğer boyutlarda elde edilen doğrulukların bu değer altında olduğu görülmektedir. Bu noktada gözlemlenen diğer önemli bir husus ReliefF algoritmasının belirlediği ve sıraladığı özelliklerin ilk 75'nin kullanımı ile HIZ algoritması en düşük performans sergilerken, veri setine dahil edilen 25 yeni bant ile HIZ algoritmasının performansında %6 seviyelerinde artış olduğu görülmektedir. Bu durum veri setine dahil edilen 25 özelliğin sınıflandırma performansı üzerindeki etkisini açıkça göstermektedir. 100 banttan sonra veri seti boyutunun arttırılması sonucunda birkaç farklı veri seti ile en yüksek doğruluğa ulaşılırken, özellik seçiminin HIZ algoritmasının performansı açısından önemi hale geldiği görülmektedir.




10 bantlı veri setleri




20 bantlı veri setleri




30 bantlı veri setleri




40 bantlı veri setleri




50 bantlı veri setleri




75 bantlı veri setleri



100 bantlı veri setleri



150 bantlı veri setleri



200 bantlı veri setleri


**Şekil 4.10 :** Obje tabanlı yaklaşımda farklı boyutta veri setleri için HIZ algoritmasının sınıflandırma performansı.

#### 4.5.7 Çoklu hızlandırma yöntemiyle obje tabanlı sınıflandırma


Çoklu hızlandırma (ÇH) algoritması hızlandırma ve torbalama algoritmalarının belirli özelliklerinin bir algortmada da toplanarak daha güçlü bir iyileştirme yöntemi oluşturulması esasına dayanmaktadır. Bu nedenle ÇH algoritması hızlandırma ve torbalama algoritmalarının birleşimi gibi düşünülebilir. Bu algoritma ile oluşturulacak sınıflandırma modelinde ağırlıklı eşik değeri, alt komitelerin sayısı ve iterasyon sayısı olarak bilinen üç farklı parametrenin kullanıcı tarafından belirlenmektedir. Her bir veri seti için ayrı ayrı optimum parametreler belirlenmiş (Çizelge A.3) ve ÇH algoritması için elde edilen sınıflandırma doğrulukları Şekil 4.11’de gösterilmiştir.

Şekil incelendiğinde ÇH algoritması ile 20 bantlı veri setleri haricinde 75 banda kadar elde edilen en yüksek sınıflandırma doğruluklarının %86 seviyelerinde olduğu görülmektedir. Şekilde 20 bantlı veri setleri içerisinde OneR algoritması ile elde edilen en yüksek doğruluk değerinin %88 düzeyinde olduğu, 100 ve 200 bantlı veri setleri içinde benzer sonuçlar elde edildiği görülmektedir. Bununla birlikte, tüm sınıflandırma sonuçları içerisinde 75 ve 150 bantlı veri setleri ile ÇH algoritmasının %90’ın üzerinde performans sergilediği, hesaplanan diğer doğrulukların %89’un altında olduğu tespit edilmiştir. Bu veri seti boyutlarında hesaplanan en yüksek doğruluk değerleri aynı olup, 75 bantta T-test, 150 bantta ReliefF algoritmasının belirlediği özelliklerle bu sonuç elde edilmiştir.


Şekilden de görüleceği üzere ÇH algoritmasının sınıflandırma performansı 75 bantlı veri seti kullanımına kadar kullanılan veri setine göre değişiklik gösterirken, bu noktadan sonra 150 ve 200 bantlı veri setleri için benzer doğruluklar elde edilmiştir. Nitekim 150 bantlı veri setleri içerisinde ReliefF haricindeki diğer algoritmalara ait veri setleri ile %88 doğruluk seviyesinde sonuçlar elde edilmiştir. Özellikle 200 bantlı veri setleri için elde edilen sonuçlar incelendiğinde, 7 algoritmanın (ChiSq, Fisher, GainR, NaiveB, OneR, ProbSig ve DVM-ÖÖE) seçtiği 200 özellik ile ÇH sınıflandırıcısının en yüksek doğruluğa ulaştığı görülmektedir. Bu durum söz konusu veri seti boyutlarında özellik seçiminde kullanılacak algoritmanın önemsiz hale geldiğini ve tüm veri setleri için genel olarak aynı sınıflandırma performansının elde edildiğini göstermektedir.




10 bantlı veri setleri




20 bantlı veri setleri




30 bantlı veri setleri




40 bantlı veri setleri




50 bantlı veri setleri




75 bantlı veri setleri



100 bantlı veri setleri



150 bantlı veri setleri



200 bantlı veri setleri


**Şekil 4.11 :** Obje tabanlı yaklaşımda farklı boyutta veri setleri için ÇH algoritmasının sınıflandırma performansı.

#### 4.5.8 Rotasyon orman algoritması ile obje tabanlı sınıflandırma


Rotasyon orman (RotOR) algoritmasının kullanımında bölünme ve iterasyon sayısı kullanıcı tarafından belirlenen parametrelerdir. Söz konusu parametrelere ait optimum değerler her bir veri seti için ayrı ayrı belirlenmiş (Çizelge A.2) ve sınıflandırma işleminde optimum parametrelere dayalı sınıflandırma modelleri ile elde edilen sınıflandırma doğrulukları Şekil 4.12’de gösterilmiştir.

Şekil incelendiğinde 75 bantlı veri setleri kullanımına kadar RotOR algoritmasının her bir veri seti boyutunda tek bir veri seti ile en yüksek doğruluğa ulaştığı, bu noktadan sonra birden fazla veri seti ile en yüksek doğruluğun elde edildiği görülmektedir. 10 bantlı veri setleri içerisinde en yüksek doğruluk Fisher algoritmasına ait veri seti ile elde edilirken 20 bantlı veri setleri içerisinde RF algoritmasına ait veri setiyle en yüksek doğruluğa ulaşılmıştır. 30, 40, 50 ve 75 bantlı veri setleri içerisinde RotOR algoritması için hesaplanan en yüksek sınıflandırma doğruluklarının DVM-ÖÖE algoritmasının belirlediği özellik kombinasyonları ile elde edildiği şekilden de görülmektedir. 75 banttan sonra hesaplanan sınıflandırma doğruluklarının birbirine benzer olduğu hatta birkaç veri seti ile aynı sınıflandırma doğruluklarına ulaşıldığı tespit edilmiştir. Örneğin, 100 bantlı veri setleri içerisinde GainR, InfoG, RF ve DVM-ÖÖE verileri ile en yüksek doğruluğa ulaşılırken, veri seti boyutu 150’ye çıkarıldığında Fisher, GainR, NaiveB, ReliFF ve RF veri setleri ile en yüksek sonuçlar elde edilmiştir.


RotOR algoritmasının sınıflandırma performansı toplam veri setinin %93’nü kapsayan 200 bantlı veri setleri için analiz edildiğinde ChiSq, Fisher, GainR ve InfoG veri setleri ile en yüksek doğruluğa ulaşıldığı, diğer veri setleri ile %90 seviyelerinde doğruluk elde edildiği görülmektedir. RotOR algoritmasının yüksek boyutlu veri setleri için sergilediği sınıflandırma performansı, 75 banttan sonra özellik seçiminin sınıflandırıcının performansını pozitif olarak etkileyecek bir katkı sağlamadığı ifade edilebilir. Tüm sınıflandırma sonuçları bir arada değerlendirildiğinde, RotOR sınıflandırıcısının 40 ve 50 bantlı veri setleri ile %93’ün üzerinde sınıflandırma doğruluğu elde ettiği, diğer veri seti boyutları için hesaplanan doğrulukların bu seviyenin altında kaldığı görülmektedir. Küçük boyutlu veri setleri içerisinde RotOR algoritmasının en düşük sınıflandırma doğruluklarını Pearson ve ReliefF veri setleri kullanımıyla elde ettiği ifade edilebilir.




10 bantlı veri setleri




20 bantlı veri setleri




30 bantlı veri setleri




40 bantlı veri setleri




50 bantlı veri setleri




75 bantlı veri setleri



100 bantlı veri setleri



150 bantlı veri setleri



200 bantlı veri setleri

**Şekil 4.12 :** Obje tabanlı yaklaşımda farklı boyutta veri setleri için RotOR algoritmasının sınıflandırma performansı.



Özellik seçimi algoritmalarının belirlediği farklı boyuttaki veri setleri için sınıflandırma algoritmalarının performanslarının ayrı ayrı değerlendirilmesinin ardından, elde edilen tüm sonuçların bir arada değerlendirilmesi amacıyla özellik seçimi algoritmalarının her bir sınıflandırıcı için elde ettiği en yüksek doğruluklar ve bu sonuca ulaşmada kullanılan bant sayıları Çizelge 4.5’de özetlenmiştir. Çizelgede özellik seçimi algoritmalarının kendi içerisinde ulaştığı en yüksek sınıflandırma doğruluğu ve bant sayısı koyu olarak gösterilmiştir. Çizelgeden de görüleceği üzere obje tabanlı sınıflandırmada özellik seçimi algoritmalarının belirlediği farklı boyuttaki veri setleri için elde edilen en yüksek sınıflandırma doğrulukları RotOR ve DVM sınıflandırıcıları ile elde edilmiştir. Diğer bir ifadeyle özellik seçimi algoritmalarının oluşturduğu farklı boyutlardaki veri setleriyle gerçekleştirilen sınıflandırma sonuçları ayrı ayrı ele alındığında, RotOR ve DVM sınıflandırıcılarının diğer sınıflandırma algoritmalarından üstün performans sergilediği görülmektedir. RotOR ve DVM algoritmalarının 50, 75, 100, 150 ve 200 bantlı veri setleri kullanarak yüksek sınıflandırma doğruluğuna ulaştıkları görülmektedir. Çizelgede farklı bant sayıları kullanılarak RotOR ve DVM algoritmalarının aynı sınıflandırma doğruluğuna ulaştığı görülmektedir. Örneğin, RotOR algoritması 200 bantlı ChiSq ve Fisher veri setleri ile %92,47 doğruluğa ulaşırken; 100 bantlı GainR, InfoG ve RF veri setleri ve 50 bantlı Pearson ve SyntUnc veri setleri kullanımıyla aynı doğruluğu elde etmiştir. Elde edilen bu sonuçlar özellik seçiminde kullanılacak algoritmanın sınıflandırma doğruluğu üzerindeki etkinliğini göstermektedir.

**Çizelge 4.5 :** Obje tabanlı yaklaşımda elde edilen sınıflandırma doğruluklarının özellik seçimi algoritmaları ve bant sayıları açısından analizi.

|         | EYK |       | KA  |       | DVM        |              | RO  |       | TRB |       | HIZ |       | ÇH  |       | RotOR      |              |
|---------|-----|-------|-----|-------|------------|--------------|-----|-------|-----|-------|-----|-------|-----|-------|------------|--------------|
|         | BS  | GD    | BS  | GD    | BS         | GD           | BS  | GD    | BS  | GD    | BS  | GD    | BS  | GD    | BS         | GD           |
| ChiSq   | 50  | 78,77 | 200 | 82,19 | 75         | 91,78        | 150 | 88,36 | 50  | 85,62 | 150 | 87,67 | 150 | 88,36 | <b>200</b> | <b>92,47</b> |
| Fisher  | 40  | 85,67 | 20  | 82,88 | 100        | 91,78        | 75  | 87,67 | 100 | 84,93 | 100 | 90,41 | 150 | 89,04 | <b>200</b> | <b>92,47</b> |
| GainR   | 20  | 82,19 | 100 | 81,51 | 150        | 91,78        | 200 | 90,41 | 200 | 84,93 | 200 | 87,67 | 150 | 89,04 | <b>100</b> | <b>92,47</b> |
| InfoG   | 10  | 87,67 | 40  | 83,56 | 75         | 91,78        | 150 | 89,73 | 40  | 84,93 | 200 | 86,99 | 150 | 87,67 | <b>100</b> | <b>92,47</b> |
| NaiveB  | 30  | 82,88 | 30  | 83,56 | <b>75</b>  | <b>92,47</b> | 200 | 91,10 | 150 | 86,99 | 30  | 87,67 | 200 | 88,36 | 150        | 91,78        |
| OneR    | 40  | 87,67 | 40  | 85,62 | <b>100</b> | <b>91,78</b> | 150 | 89,04 | 40  | 88,36 | 20  | 88,36 | 20  | 88,36 | 200        | 91,10        |
| Pearson | 30  | 79,45 | 150 | 81,51 | <b>75</b>  | <b>92,47</b> | 150 | 88,36 | 100 | 85,62 | 150 | 87,67 | 100 | 87,67 | <b>50</b>  | <b>92,47</b> |
| ProbSig | 20  | 84,93 | 20  | 84,93 | <b>75</b>  | <b>91,78</b> | 150 | 89,73 | 20  | 87,67 | 200 | 87,67 | 150 | 88,36 | <b>50</b>  | <b>91,78</b> |
| ReliefF | 20  | 76,71 | 150 | 80,82 | <b>75</b>  | <b>93,15</b> | 150 | 91,10 | 200 | 85,62 | 100 | 90,41 | 150 | 90,41 | 50         | 92,47        |
| RF      | 20  | 86,30 | 150 | 82,19 | 100        | 91,78        | 30  | 89,04 | 50  | 86,30 | 150 | 87,67 | 200 | 87,67 | <b>100</b> | <b>92,47</b> |
| DVM-ÖÖE | 75  | 77,40 | 40  | 81,51 | 40         | 93,84        | 75  | 91,78 | 200 | 84,93 | 75  | 89,73 | 200 | 88,36 | <b>50</b>  | <b>94,52</b> |
| SyntUnc | 20  | 84,25 | 20  | 82,88 | 150        | 91,78        | 150 | 90,41 | 20  | 85,62 | 50  | 87,67 | 150 | 87,67 | <b>50</b>  | <b>92,47</b> |
| t-test  | 20  | 85,62 | 20  | 80,82 | <b>150</b> | <b>92,47</b> | 100 | 91,10 | 100 | 86,99 | 100 | 87,67 | 75  | 90,41 | 200        | 91,78        |

\*BS: Bant sayısı, GD: Genel sınıflandırma doğruluğu

Özellik seçimi algoritmaları ayrı ayrı ele alındığında, çizelgeden de görüleceği üzere ChiSq ve Fisher algoritmalarının seçtiği 200 bantlı veri setlerinin RotOR algoritması ile sınıflandırılması sonucunda en yüksek doğruluk değerlerine (%92,47) ulaşıldığı görülmektedir. ChiSq algoritmasının belirlediği diğer bant kombinasyonları ile DVM haricindeki diğer sınıflandırma algoritmalarının en iyi performansları %90'ın altında kalmıştır. Aynı şekilde Fisher algoritmasının belirlediği bant dizilimleri ile HIZ ve TRB algoritmaları hariç diğer algoritmaların performansının da %90'ın altında olduğu görülmektedir.

Çizelge incelendiğinde t-testi ile belirlenen bant kombinasyonları içinde 150 banttan oluşan veri setiyle DVM algoritmasının en yüksek doğruluğu (%92,47) elde ettiği görülmektedir. GainR, InoG, RF ve OneR algoritmalarının belirlediği farklı boyutta veri setleri içerisinde ise ilk 100 bantı içeren verilerin kullanımıyla en yüksek sınıflandırma doğruluklarına ulaşıldığı görülmektedir. Çizelgeden de görüleceği üzere RotOR algoritması GainR, InfoG ve RF tarafından belirlenen 100 bantla %92,47, DVM algoritması ise OneR algoritmasının seçtiği 100 bantı kullanarak %91,78 doğruluğa ulaşmıştır.


Çizelgede NaiveB, Pearson, ProbSig ve ReliefF algoritmalarının belirlediği 9 farklı boyuttaki veri setleri içerisinde en yüksek doğrulukların 75 bantı içeren veri setlerinin DVM ile sınıflandırılması sonucunda elde edildiği görülmektedir. DVM 75 bantlı ReliefF veri setiyle %93,15, Pearson veri setiyle %92,47, ProbSig ve NaiveB veri setleriyle %91,78 doğruluğa ulaşmıştır.

Çizelge incelendiğinde, RotOR algoritmasının Pearson, ProbSig, DVM-ÖÖE ve SymtUnc algoritmalarının seçtiği 50 özellekle yüksek sınıflandırma doğruluğuna ulaştığı görülmektedir. RotOR algoritması DVM-ÖÖE ile seçilen 50 özellekle obje tabanlı sınıflandırma için hesaplanan en yüksek sınıflandırma doğruluğuna (%94,52) ulaşırken, 50 bantlı Pearson ve SymtUnc veri setleri ile %92,47, ProbSign veri setiyle %91,78 sınıflandırma doğruluğu elde etmiştir.

## 5. PİKSEL TABANLI SINIFLANDIRMA

Piksel tabanlı sınıflandırma işleminin esası görüntü üzerindeki piksellere ait spektral özellikler göz önüne alınarak, her bir pikselin önceden belirlenen bir arazi örtüsü veya kullanım sınıfına atanmasına dayanmaktadır. Piksel tabanlı sınıflandırma işleminde genel olarak takip edilen işlem adımları arazi örtüsü/kullanımını temsil edecek yeter sayıda örnek piksellerin belirlenmesi, söz konusu pikseller ile sınıflandırmada kullanılacak algoritmanın eğitilmesi ve elde edilen sınıflandırma modelinin tüm görüntüye uygulanarak arazi örtüsü/kullanımını temsil eden tematik harita üretilmesi şeklindedir (Şekil 5.1).

Piksel tabanlı sınıflandırmaya esas olacak veri seti, WV-2 uydu görüntüsünün 8 spektral bandını, yardımcı veri olarak tanımlanan 12 vejetasyon indeksini, temel bileşenler analizi ile hesaplanan ilk üç bileşeni, uydu görüntüsünün spektral bantları kullanılarak hesaplanan 8 doku özelliğini ve WV-2'nin kırmızı, yeşil, mavi, kızılötesi-1 ve kızılötesi-2 bantlarının çeşitli kombinasyonları kullanılarak oluşturulan 3 farklı ton-doygunluk-yoğunluk özelliğini içermektedir. Sonuç olarak piksel tabanlı sınıflandırma işleminde 96 özelliği (bandı) içeren çok boyutlu veri seti değerlendirmeye alınmıştır.



**Şekil 5.1 :** Piksel tabanlı sınıflandırma yaklaşımında temel işlem adımları.

## 5.1 Eğitim ve Test Veri Setlerinin Oluşturulması

Tez kapsamında önerilen yöntem ve yaklaşımların bir arada değerlendirilmesi ve elde edilen sonuçların objektif bir şekilde karşılaştırılabilmesi için obje tabanlı sınıflandırma işlemi sırasında kullanılan eğitim ve test alanları piksel tabanlı sınıflandırma işleminde de kullanılmıştır. Arazi örtüsü/kullanımını temsil eden söz konusu alanlar içerisinde rastgele örnekleme prensibinden hareketle 13 arazi örtüsü/kullanımı sınıfı için eşit sayıda örnek pikseller seçilerek eğitim ve test veri setleri oluşturulmuştur. Çizelge 5.1’den de görüleceği üzere eğitim verisi olarak her bir sınıf için 200 piksel içerecek şekilde toplam 2.600 piksel, test verisi olarak her bir sınıf için 150 pikseli içerecek şekilde toplam 1.950 piksel belirlenmiştir.


**Çizelge 5.1 :** Sınıflandırmaya esas eğitim ve test verilerini oluşturan piksellerin arazi örtüsü/kullanımı sınıflarına göre dağılımı.

| Sınıf adı    | Eğitimde kullanılan piksel sayısı | Testte kullanılan piksel sayısı |
|--------------|-----------------------------------|---------------------------------|
| Fıstık Çamı  | 200                               | 150                             |
| Kızıl Çam    | 200                               | 150                             |
| Sedir        | 200                               | 150                             |
| Çınar        | 200                               | 150                             |
| Zeytin       | 200                               | 150                             |
| Su           | 200                               | 150                             |
| Bozkır       | 200                               | 150                             |
| Toprak       | 200                               | 150                             |
| Bina-Kırmızı | 200                               | 150                             |
| Bina-Gri     | 200                               | 150                             |
| Bina-Beyaz   | 200                               | 150                             |
| Yol          | 200                               | 150                             |
| Gölge        | 200                               | 150                             |

## 5.2 Özellik (bant) Seçimi ve Boyut İndirgeme

WorldView-2 uydu görüntüsü ve yardımcı verilerin birleştirilmesi ile elde edilen 96 özelliğe (banda) sahip veri seti içerisinde sınıflar arasındaki ayrımın en etkili şekilde gerçekleştirilmesine olanak sağlayan bantların tespit edilmesi ve gereksiz/faydasız bilgi içeren bantların elenerek boyut indirgemesi amacıyla özellik seçimi yoluna gidilmiştir. Bu amaca yönelik takip edilen işlem adımları Şekil 5.2’de gösterilmiştir. Özellik seçiminin gerçekleştirilmesinde obje tabanlı sınıflandırma yaklaşımında da değerlendirmeye alınan 13 algoritma kullanılmıştır. Optimum özellik boyutunun tespit edilmesi amacıyla söz konusu algoritmalar tarafından

belirlenen sıralamalar dikkate alınarak en iyi 10, 20, 30, 40, 50, 75 ve 90 özelliği içerecek şekilde 7 farklı veri seti oluşturulmuştur. Her bir özellik seçimi algoritması için ayrı ayrı oluşturulan farklı boyutlardaki veri setleri sınıflandırma işlemine tabi tutularak özellik boyutundaki artışın sınıflandırma doğruluğuna olan etkileri incelenmiş ve önerilen özellik seçimi algoritmalarının performansı analiz edilmiştir. Özellik seçimi sonucunda 91 farklı eğitim ve test veri seti (13 özellik seçimi algoritması sonuçlarına göre üretilen 7 farklı veri seti boyutu) sınıflandırma işlemine tabi tutulmuştur. Söz konusu veri setlerinin sınıflandırılmasında obje tabanlı yaklaşımında da kullanılan makine öğrenme algoritmaları ve en yakın komşuluk algoritmasından yararlanılmıştır.



**Şekil 5.2 :** Özellik seçimi işleminde takip edilen işlem adımları.

### 5.3 Piksel Tabanlı Sınıflandırma İçin Performans Analizi

Özellik seçimi sonucunda oluşturulan veri setleri kullanılarak tezde dikkate alınan 8 sınıflandırma yönteminin performansı ayrı ayrı analiz edilmiştir. Analizlerde öncelikli olarak her bir algoritmanın sınıflandırma performansı özellik seçimi algoritmalarınca belirlenen farklı boyutlarda veri setleri dikkate alınarak kendi


içerisinde ayrıntılı olarak incelenmiştir. Analiz sonucunda her bir sınıflandırıcı için en yüksek sınıflandırma doğruluğunun elde edildiği veri seti ve optimum veri seti boyutu belirlenmiştir. Daha sonra sınıflandırıcıların performansları birbirleriyle karşılaştırılarak dikkate alınan sınıflandırma algoritmaları içerisinde en üstün performansı gösteren algoritma belirlenmiştir. Tez kapsamında önerilen özellik seçimi yaklaşımı ile piksel tabanlı sınıflandırma işleminin gerçekleştirilmesinde etkili özellik seçimi algoritması, spektral ayırım için en uygun bantlar, optimum bant sayısı ve en yüksek sınıflandırma performansının elde edildiği sınıflandırma algoritması ortaya koyulmuştur.

### **5.3.1 En yakın komşuluk algoritması ile piksel tabanlı sınıflandırma**

En yakın komşuluk (EYK) sınıflandırıcısı ile farklı boyutta ve farklı özellik seçimi algoritmaları tarafından oluşturulan veri setleri ayrı ayrı değerlendirilmiş ve sınıflandırıcının performansı analiz edilmiştir. EYK algoritması ile söz konusu veri setlerinin sınıflandırılması sonucunda hesaplanan genel doğruluklar Şekil 5.3’de verilmiştir.

Şekilden de görüleceği üzere EYK için elde edilen en düşük sınıflandırma doğruluklarının tamamı t-test algoritması tarafından oluşturulan bant kombinasyonları kullanımıyla elde edilmiştir. Şekil incelendiğinde 10, 20, 30 ve 40 bantta sahip veri setleri ile EYK algoritmasının %80 üzerinde genel doğruluklara ulaştığı, diğer veri seti boyutlarında %79 seviyelerinde doğruluklar elde edildiği görülmektedir. 10 bantlı veri setleri içerisinde en yüksek doğruluğa RF algoritmasının seçtiği bant kombinasyonu ile ulaşılırken, 20 ve 30 bantlı veri setleri içerisinde DVM-ÖÖE ile seçilen bantlar ile yüksek doğruluklar elde edilmiştir. Bu veri seti boyutundan sonra özellik seçiminin EYK algoritmasının performansını önemli derecede etkileyecek bir katkısının olmadığı ifade edilebilir.

40 bantlı veri setleri içerisinde Pearson algoritmasına ait veri seti ile yaklaşık %81 doğruluk elde edilirken, diğer veri setleri için EYK performansı %79 düzeyinde kalmıştır. 50, 75 ve 90 bantlı veri setleri için elde edilen genel doğruluklar ise birbirine benzer özellikte olup t-test haricindeki tüm veri setleri ile yaklaşık %79 seviyelerinde sonuçlar elde edilmiştir. Özellikle veri seti boyutu 90 olarak değerlendirmeye alındığında Fisher, NaiveB, Pearson, RF ve DVM-ÖÖE ile EYK ile en yüksek doğruluğa ulaşıldığı görülmektedir.




**Şekil 5.3 :** Piksel tabanlı yaklaşımda farklı boyutta veri setleri için EYK algoritmasının sınıflandırma performansı.

### 5.3.2 Karar ağaçları algoritması ile piksel tabanlı sınıflandırma

Tez kapsamında piksel tabanlı sınıflandırma işleminde tek değişkenli karar ağacı algoritmalarından C4.5 algoritması kullanılmış ve ağaç yapısında dallanmaya esas olacak özelliklerin seçiminde kazanç oranı kriteri esas alınmıştır. Değerlendirmeye alınan her bir veri seti için ayrı bir ağaç yapısı oluşturulmuş ve söz konusu modellere üretilen sınıflandırma doğrulukları Şekil 5.4’de verilmiştir. Sınıflandırma

doğrulukları incelendiğinde OneR algoritmasının seçtiği 20 özellik ve DVM-ÖÖE ile belirlenen 40 özelliğe sahip veri setleri kullanılarak KA algoritmasının sınıflandırma performansının %82'nin üzerinde olduğu görülmektedir. Diğer veri setleri için elde edilen sınıflandırma doğrulukları %81'in altındadır. Diğer taraftan KA sınıflandırıcısının Pearson ve t-test algoritmalarının belirlediği özellikleri kullanarak en düşük doğruluk değerlerine ulaştığı tespit edilmiştir.



**Şekil 5.4 :** Pikel tabanlı yaklaşımda farklı boyutta veri setleri için KA algoritmasının sınıflandırma performansı.




Veri seti boyutu 30'dan 40'a çıktığında DVM-ÖÖE haricindeki diğer veri setleri kullanımıyla KA sınıflandırıcısı %3 daha düşük performans sergileyerek %78 düzeyinde doğruluğa ulaşabilmiştir. Şekil incelendiğinde, 50, 75 ve 90 bantlı veri setleri için elde edilen sınıflandırma sonuçlarının birbirine benzer özellikler taşıdığı tespit edilmiştir. Bu nedenle KA sınıflandırıcısı için bu veri seti boyutlarında özellik seçiminin anlamsız oluğu ifade edilebilir.

### 5.3.3 Destek vektör makineleri algoritması ile piksel tabanlı sınıflandırma

Tez kapsamında destek vektör makineleri (DVM) ile piksel tabanlı sınıflandırma işleminin gerçekleştirilmesinde kernel fonksiyonu olarak radyal tabanlı kernel fonksiyonundan yararlanılmış, düzenleme parametresi ( $C$ ) ve kernel genişliği ( $\gamma$ ) değerlendirmeye alınan her farklı veri seti için ayrı ayrı tespit edilmiştir. DVM ile elde edilen genel sınıflandırma doğruluklarına ait grafikler Şekil 5.5'de verilmiştir. Şekil incelendiğinde, 10 bantlı veri setleri içerisinde en yüksek doğruluğun NaiveB algoritmasının belirlediği özelliklerle elde, Fisher, GainR, DVM-ÖÖE ve SymtUnc veri setleri için DVM'nin benzer sınıflandırma performansı sergilediği görülmektedir. Bu boyutta elde edilen en düşük doğruluk t-test veri seti kullanımı sonucunda hesaplanmıştır.

DVM algoritmasının performansı 20, 30, 40 ve 50 bantlı veri setleri açısından değerlendirmeye alındığında, söz konusu bant aralıklarında DVM-ÖÖE ile seçilen özelliklerle en yüksek sınıflandırma doğruluklarına ulaşıldığı görülmektedir. Bu aralıkta özellikle DVM-ÖÖE ile seçilen 40 bandın kullanımıyla DVM'nin sınıflandırma performansında yaklaşık %3 artış olduğu görülmektedir. Diğer taraftan söz konusu veri seti boyutlarında hesaplanan en düşük doğrulukların Fisher ve t-test algoritmalarının oluşturduğu özelliklerin kullanımıyla elde edildiği ifade edilebilir.

DVM algoritması 75 bantlı veri setleri içerisinde ChiSq veri seti ile en yüksek doğruluğa ulaşılırken, InfoG ve ProbSig veri setleri ile benzer sınıflandırma sonuçları elde etmiştir. 90 bantlı veri setleri açısından sonuçlar incelendiğinde GainR veri setiyle en yüksek sonuca ulaşılmasına rağmen DVM diğer veri setleri kullanımıyla bu sonuca yakın performans göstermiştir.




**Şekil 5.5 :** Piksel tabanlı yaklaşımda farklı boyutta veri setleri için DVM algoritmasının sınıflandırma performansı.

### 5.3.4 Rastgele orman algoritması ile piksel tabanlı sınıflandırma

Rastgele orman (RO) algoritması kullanılarak piksel tabanlı sınıflandırma işleminin gerçekleştirilmesinde kullanıcı tarafından belirlenmesi gereken parametreler (her bir düğümdeki özellik ve ağaç sayısı) dikkate alınan tüm veri setleri için ayrı ayrı belirlenmiştir. RO algoritması kullanımıyla elde edilen sınıflandırma doğrulukları Şekil 5.6'da gösterilmiştir. Sonuçlar incelendiğinde RO algoritmasının 50, 75 ve 90

bantlı veri setleri ile %86 üzerinde doğruluğa ulaştığı, diğer veri setleri ile %84 seviyelerinde sonuçlar ürettiği görülmektedir. RO algoritması %84 üzerindeki doğruluk değerlerine RF algoritmasının belirlediği 50 bant, Pearson algoritmasının belirlediği 75 bant ve Fisher algoritmasının belirlediği 90 bant ile ulaşmıştır. RO algoritması için elde edilen tüm sonuçlar içerisinde en düşük sınıflandırma doğruluklarının ise Pearson ve t-test veri setleri ile elde edildiği görülmektedir.



**Şekil 5.6 :** Pikel tabanlı yaklaşımda farklı boyutta veri setleri için RO algoritmasının sınıflandırma performansı.


Şekilde 30, 40, 50 ve 75 bantlı veri setleri için hesaplanan doğruluklar göz önüne alındığında, t-test haricindeki diğer verilerle RO algoritmasının benzer sınıflandırma doğruluğuna ulaştığı görülmektedir. Bu veri seti boyutlarında özellik seçiminde kullanılan algoritmanın RO sınıflandırıcısının performansını etkileyecek derecede bir öneme sahip olmadığı ve veri setine dahil edilen bantların sonuç üzerinde sınırlı düzeyde katkı sağladığı ifade edilebilir. Diğer taraftan 50 banttan sonra veri setine dahil edilen bantların RO algoritmasının sınıflandırma doğruluğunu olumsuz olarak etkilediği ifade edilebilir.

### **5.3.5 Torbalama algoritması ile piksel tabanlı sınıflandırma**

Torbalama algoritmasıyla sınıflandırmada torba boyutu ve iterasyon sayısı olarak bilinen iki parametrenin kullanıcı tarafından belirlenmesi gerekmektedir. Piksel tabanlı sınıflandırma işleminin gerçekleştirilmesinde söz konusu parametre değerleri değerlendirmeye alınan her farklı veri seti için ayrı ayrı tespit edilmiştir. Torbalama algoritması (TRB) ile farklı boyutta ve farklı özellik seçimi algoritmaları tarafından oluşturulan veri setleri ayrı ayrı değerlendirilmiş ve hesaplanan doğruluklar Şekil 5.7’de gösterilmiştir.

Şekilde 10 bantlı içeren veri setleri ele alındığında ProbSig veri seti ile en yüksek doğruluğa ulaşılırken, Pearson veri seti ile bu sonuca oldukça yakın sınıflandırma doğruluğuna ulaşılmıştır. TRB performansı 20 bantlı veri setleri açısından ele alındığında SymtUnc veri setiyle matematiksel olarak en yüksek sınıflandırma doğruluğuna ulaşılırken, ChiSq, InfoG, OneR ve ProbSig veri setleriyle TRB algoritması en yüksek doğruluğa benzer sınıflandırma sonuçları üretmiştir. 30 bantlı veri setleri için elde edilen sonuçlar incelendiğinde, GainR algoritmasının seçtiği özellikler ile en yüksek doğruluğa ulaşıldığı, SymtUnc veri seti ile bezer sınıflandırma sonuçları elde edildiği görülmektedir.

40, 50, 75 ve 90 bantlı veri setleri için TRB algoritmasının sınıflandırma performansı göz önüne alındığında, hesaplanan sınıflandırma doğruluklarının %80 düzeyinde olduğu görülmektedir. Elde edilen bu sonuç söz konusu bant aralıklarında kullanılacak özellik seçimi algoritmasının TRB performansı açısından önemsiz olduğu ifade edilebilir.




**Şekil 5.7 :** Piksel tabanlı yaklaşımda farklı boyutta veri setleri için TRB algoritmasının sınıflandırma performansı.

### 5.3.6 Hızlandırma algoritması ile piksel tabanlı sınıflandırma

Hızlandırma algoritması (HIZ) ile sınıflandırma işleminde kullanıcı tarafından belirlenen iterasyon sayısı her veri seti için ayrı ayrı belirlenmiş ve elde edilen genel sınıflandırma doğrulukları Şekil 5.8’de gösterilmiştir. Şekil incelendiğinde 10 bantlı veri setleri içerisinde GainR veri seti ile en yüksek doğruluğa ulaşılırken, 20 ve 30 banda sahip veri setleri içerisinde, SyntUnc ve ReliefF algoritmalarının seçtiği


özelliklerle en yüksek genel sınıflandırma doğruluk elde edilmiştir. Bu bant aralıklarında HIZ algoritmasının ProbSig veri setiyle en yüksek sınıflandırma sonuçlarına yakın performanslar sergilediği tespit edilmiştir. Şekilden de görüleceği üzere 40, 50, 75 ve 90 bantlı veri setleri için HIZ algoritması tüm veri setleri ile benzer sınıflandırma performansları sergilemiştir.



**Şekil 5.8 :** Pksel tabanlı yaklaşımda farklı boyutta veri setleri için HIZ algoritmasının sınıflandırma performansı.

### 5.3.7 Çoklu hızlandırma yöntemiyle piksel tabanlı sınıflandırma

Çoklu hızlandırma (ÇH) algoritması ile piksel tabanlı sınıflandırma işleminin gerçekleştirilmesinde kullanıcı tarafından belirlenen parametreler (ağırlıklı eşik değeri, alt komitelerin sayısı ve iterasyon sayısı) her bir veri seti için ayrı ayrı tespit edilerek uygulamalarda optimum parametre değerleri kullanılmıştır. ÇH algoritması için elde edilen sınıflandırma doğrulukları Şekil 5.9’da gösterilmiştir.



Şekil 5.9 : Piksel tabanlı yaklaşımda farklı boyutta veri setleri için ÇH algoritmasının sınıflandırma performansı.

Şekil incelendiğinde 10 bantlı veri setleri içinde en yüksek doğruluğa GainR veri setiyle ulaşıldığı, SymtUnc veri seti ile ÇH algoritmasının benzer performans sergilediği görülmektedir. 20 ve 30 bantlı veri setleri göz önüne alındığında ProbSig veri setleriyle her iki bant aralığında da en yüksek doğrulukların elde edildiği belirlenmiştir. 20 bantta SymtUnc veri setiyle, 30 bantta ise ReliefF veri seti ile yine en yüksek doğruluk değerlerine ulaşılmıştır.

Şekilden de görüleceği üzere 30 banttan sonra veri setine ilave edilen yeni bantlar ÇH algoritmasının performansını olumlu şekilde etkilemediği, bu noktadan sonra tüm veri setleri için ÇH algoritmasının benzer performanslar sergilediği söylenebilir. Örneğin şekilde 50 bantlı veri setleri içerisinde ChiSq, DVM-ÖÖE ve t-test ile matematiksel olarak en yüksek sınıflandırma doğruluğuna ulaşıldığı diğer veri setleri ile bu doğruluk değerine çok yakın sınıflandırma sonuçları elde edildiği görülmektedir. Bu sonuç kullanılan veri setinin veya kullanılan özellik seçimi algoritmasının ÇH algoritmasının performansını etkileyen bir unsur olmadığı ifade edilebilir.


### **5.3.8 Rotasyon orman algoritması ile piksel tabanlı sınıflandırma**

Rotasyon orman (RotOR) algoritması ile piksel tabanlı sınıflandırma işleminin gerçekleştirilmesinde kullanıcı tarafından belirlenen parametreler (bölünme ve iterasyon sayısı) değerlendirmeye alınan her bir veri seti için ayrı ayrı tespit edilerek uygulamada optimum parametre değerleri kullanılmıştır. RotOR algoritması ile elde edilen sınıflandırma doğrulukları Şekil 5.10'da gösterilmiştir.

RotOR algoritmasının sınıflandırma performansı incelendiğinde, 50 banda kadar kullanılan veri setinin RotOR algoritmasının performansını önemli derecede etkilediği görülmektedir. Örneğin RotOR algoritması 10 bantlı veri setleri içerisinde GainR algoritmasının seçtiği özellikler ile %86 doğruluğa ulaşırken, ReliefF algoritmasına ait veri seti kullanımıyla %78 seviyelerinde doğruluk elde etmiştir. 50 banttan sonra özellik seçimi sonucunda elde edilen 13 farklı veri seti için RotOR algoritmasının benzer sınıflandırma performansı sergilediği şekilden de görülmektedir. Örneğin 90 bantlı veri setleri göz önüne alındığında, t-test veri setiyle yaklaşık %86 sınıflandırma doğruluğuna ulaşılırken, diğer özellik seçimi algoritmalarının belirlediği bant kombinasyonları için %84 seviyelerinde sınıflandırma doğruluğu elde edilmiştir. Şekilden de görüleceği üzere RotOR



algoritması için hesaplanan tüm sınıflandırma sonuçları bir arada değerlendirildiğinde en yüksek sınıflandırma doğruluklarının 10, 20 ve 30 bantta sahip veri setleri ile elde edilmiştir. En yüksek doğruluklara ulaşmada kullanılan veri setlerinin GainR ve DVM-ÖÖE özellik seçimi algoritmaları tarafından oluşturulduğu görülmektedir.



**Şekil 5.10 :** Piksel tabanlı yaklaşımda farklı boyutta veri setleri için RotOR algoritmasının sınıflandırma performansı.

Özellik seçimi algoritmalarının belirlediği farklı boyuttaki veri setleri için sınıflandırma algoritmalarının performanslarının ayrı ayrı değerlendirilmesinin ardından, elde edilen sonuçlar özellik seçimi algoritmaları açısından değerlendirmeye alınmıştır. Bu amaçla özellik seçimi algoritmalarının her bir sınıflandırıcı için elde ettiği en yüksek doğruluklar ve bu sonuca ulaşmada kullanılan bant sayıları Çizelge 5.2’de özetlenmiştir. Çizelgede özellik seçimi algoritmalarının kendi içerisinde ulaştığı en yüksek sınıflandırma doğruluğu ve bant sayısı koyu olarak gösterilmiştir. Çizelgeden de görüleceği üzere özellik seçimi algoritmalarının oluşturduğu veri setleri ile elde edilen en yüksek sınıflandırma doğruluklarına DVM, RO ve RotOR sınıflandırıcıları ile ulaşılmıştır. En yüksek doğrulukların elde edilmesinde kullanılan bant sayıları analiz edildiğinde, DVM-ÖÖE ile belirlenen 40 bantlı veri seti ve t-test ile belirlenen 90 bantlı veri seti haricinde diğer tüm veri setlerinin bant sayısının 50 olduğu görülmektedir. Örneğin ChiSq algoritması tarafından oluşturulan 10, 20, 30, 40, 50, 75 ve 90 bantlı veri setlerinin sınıflandırma algoritmaları tarafından ayrı ayrı sınıflandırılması neticesinde, en yüksek sınıflandırma doğruluğunun (%86,51) 50 bantlı veri setinin DVM ile sınıflandırılması ile elde edildiği görülmektedir. Aynı şekilde Fisher, GainR, InfoG, NaiveB, OneR, Pearson, ProbSig ve SymtUnc algoritmalarının seçtiği 50 bantlı veri setiyle DVM en yüksek sınıflandırma doğruluğu elde etmiştir. Elde edilen bu sonuçlar, piksel tabanlı sınıflandırmada sınıflandırma doğruluğu açısından en etkili bant sayısının 50 olduğunu gösterir niteliktedir.

**Çizelge 5.2 :** Piksel tabanlı yaklaşımda elde edilen sınıflandırma doğruluklarının özellik seçimi algoritmaları ve bant sayıları açısından analizi.

|         | EYK |       | KA |       | DVM       |              | RO        |              | TRB |       | HIZ |       | ÇH |       | RotOR     |              |
|---------|-----|-------|----|-------|-----------|--------------|-----------|--------------|-----|-------|-----|-------|----|-------|-----------|--------------|
|         | BS  | GD    | BS | GD    | BS        | GD           | BS        | GD           | BS  | GD    | BS  | GD    | BS | GD    | BS        | GD           |
| ChiSq   | 75  | 78,92 | 20 | 81,03 | <b>50</b> | <b>86,51</b> | 75        | 85,95        | 20  | 83,23 | 75  | 83,03 | 20 | 83,44 | 50        | 84,46        |
| Fisher  | 30  | 80,10 | 75 | 79,79 | <b>50</b> | <b>86,31</b> | 90        | 86,15        | 30  | 81,85 | 75  | 82,82 | 90 | 82,72 | 10        | 84,87        |
| GainR   | 20  | 79,44 | 90 | 79,79 | <b>50</b> | <b>86,05</b> | 75        | 85,69        | 30  | 83,59 | 10  | 83,59 | 10 | 83,79 | 10        | 86,00        |
| InfoG   | 75  | 78,92 | 20 | 81,44 | <b>50</b> | <b>86,31</b> | 90        | 85,13        | 20  | 83,18 | 20  | 83,54 | 20 | 84,05 | 20        | 83,90        |
| NaiveB  | 10  | 80,72 | 50 | 79,49 | <b>50</b> | <b>85,80</b> | 75        | 85,64        | 40  | 81,64 | 90  | 83,28 | 50 | 82,92 | 50        | 85,49        |
| OneR    | 75  | 79,03 | 20 | 82,62 | <b>50</b> | <b>86,31</b> | 90        | 85,23        | 20  | 82,82 | 75  | 83,18 | 20 | 82,97 | 75        | 85,33        |
| Pearson | 40  | 80,72 | 30 | 81,28 | <b>50</b> | <b>86,41</b> | 75        | 86,15        | 10  | 83,28 | 75  | 83,13 | 40 | 83,38 | 40        | 84,15        |
| ProbSig | 90  | 78,92 | 20 | 81,38 | <b>50</b> | <b>86,21</b> | 75        | 85,13        | 10  | 83,38 | 30  | 83,95 | 30 | 84,46 | 10        | 85,44        |
| ReliefF | 20  | 80,10 | 30 | 80,72 | 50        | 85,54        | 75        | 85,28        | 10  | 82,41 | 30  | 84,41 | 30 | 84,46 | <b>50</b> | <b>85,59</b> |
| RF      | 20  | 82,21 | 50 | 79,28 | 50        | 85,90        | <b>50</b> | <b>86,41</b> | 40  | 81,54 | 30  | 83,13 | 90 | 82,77 | 50        | 85,38        |
| DVM-ÖÖE | 20  | 83,74 | 40 | 83,18 | <b>40</b> | <b>88,23</b> | 90        | 85,44        | 40  | 81,44 | 90  | 83,33 | 50 | 83,08 | 30        | 86,72        |
| SymtUnc | 75  | 78,92 | 20 | 81,74 | <b>50</b> | <b>85,85</b> | 90        | 85,18        | 20  | 83,49 | 20  | 84,00 | 20 | 84,31 | 20        | 85,18        |
| t-test  | 90  | 78,21 | 90 | 77,33 | 20        | 85,13        | 90        | 84,26        | 40  | 81,90 | 20  | 82,51 | 50 | 83,08 | <b>90</b> | <b>86,00</b> |

\*BS: Bant sayısı, GD: Genel sınıflandırma doğruluğu

## **6. BULGULAR VE TARTIŞMA**


### **6.1 Veri Seti Boyutundaki Değişimlere Göre Performans Analizi**

Tez kapsamında özellik seçimi algoritmalarınca önem derecesine göre oluşturulan bant sıralamaları dikkate alınarak obje tabanlı yaklaşımda 9 farklı boyutta (10, 20, 30, 40, 50, 75, 100, 150 ve 200 bant) ve piksel tabanlı yaklaşımda 7 farklı boyutta (10, 20, 30, 40, 50, 75 ve 90 bant) veri setleri oluşturulmuştur. Oluşturulan her bir veri seti için sınıflandırma algoritmalarının performansları ayrı ayrı analiz edilerek, algoritmaların veri seti boyutundaki artışa karşılık sınıflandırma performanslarındaki değişimler ortaya koyulmuştur. Söz konusu analizler farklı algoritmalar tarafından gerçekleştirilen özellik seçimi sonucunda en yüksek doğruluğa ulaşılan veri seti göz önüne alınarak yapılmıştır. Örneğin, 13 özellik seçimi algoritması tarafından belirlenen 10 özelliği (bandı) içeren veri setleri içerisinde EYK algoritması en yüksek doğruluğa bilgi kazancı (InfoG) algoritmasının belirlediği veri seti ile ulaşmış ve analizde elde edilen bu doğruluk esas alınmıştır. Analizler neticesinde tez kapsamında değerlendirmeye alınan sınıflandırma algoritmalarının veri seti boyutuna göre performansları incelenerek, literatürde Hughes fenomeni olarak tanımlanan problemten etkilenip etkilenmedikleri ortaya koyulmuştur.

#### **6.1.1 En yakın komşuluk algoritması**


Obje tabanlı yaklaşım için en yakın komşuluk (EYK) algoritmasının veri seti boyutundaki artışa göre sınıflandırma performansı incelendiğinde, veri seti boyutundaki artışla birlikte algoritmanın sınıflandırma performansının azaldığı Şekil 6.1’de görülmektedir. Şekilden de görüleceği üzere EYK en yüksek sınıflandırma doğruluğu olan %87,67 değerine 10 ve 40 özelliği içeren veri setleri kullanımıyla ulaşmıştır. Elde edilen bu sonuç, veri seti boyutunun 10’dan 40’a çıkarılmasının EYK sınıflandırıcının performansında herhangi bir değişim ortaya çıkarmadığını göstermektedir. Diğer bir ifadeyle 10 banttan sonra veri setine dahil edilecek yeni bantlar EYK algoritmasının performansına olumlu bir katkı sağlamaktadır. Diğer taraftan 40’dan fazla özelliğin kullanılması durumunda EYK algoritmasının

performansının önemli derecede düştüğü görülmektedir. Herhangi bir özellik seçimi kullanılmaksızın obje tabanlı yaklaşımla görüntü objeleri için tanımlanan 216 özelliğin tamamının sınıflandırma işleminde kullanılması durumunda EYK ile elde edilen sınıflandırma doğruluğunun %76,03 olduğu görülmektedir. Elde edilen bu genel doğruluk 10 bantı içeren veri setiyle elde edilen doğruluktan yaklaşık %11 daha düşüktür. Diğer bir ifadeyle özellik seçimi ile veri seti boyutunun %95 oranında azalmasına karşın genel sınıflandırma doğruluğunda %11 seviyelerinde artış olduğu görülmektedir. Bu sonuç obje tabanlı yaklaşımda kullanılan EYK algoritmasının performansının veri seti boyutundaki değişimlere duyarlı olduğunu ve yüksek boyutlu veriler için sınıflandırma performansının düşük olduğunu göstermektedir.



**Şekil 6.1 :** Objeye tabanlı yaklaşımda EYK algoritmasının özellik boyutu değişimine göre sınıflandırma performansı.

Piksel tabanlı yaklaşımda EYK algoritmasının veri seti boyutundaki değişimlere göre performansı analiz edildiğinde, veri seti boyutundaki artışın sınıflandırma performansını olumsuz etkilediği tespit edilmiştir. Şekil 6.2'den de görüleceği üzere sınıflandırma performansı açısından kritik veri seti boyutu 20 olup bu noktadan sonra sınıflandırma doğruluğu azalma eğilimindedir. Şekil incelendiğinde 50 özellikten sonra değerlendirmeye alınan tüm veri setleri için EYK algoritmasının aynı sınıflandırma doğruluğuna ulaştığı görülmektedir. Herhangi bir özellik seçimi yapılmaksızın tüm bantların kullanımıyla elde edilen doğruluk 50 özellik ile elde edilen doğruluğa eşit olup %78,97 olarak hesaplanmıştır. Bu sonuç tüm veri seti boyutunun özellik seçimi uygulanmasıyla %80 azalmasına karşın sınıflandırma doğruluğunda %5 artış olduğunu göstermektedir.




**Şekil 6.2 :** Pikel tabanlı EYK algoritmasının özellik boyutu değişimine göre sınıflandırma performansı.

Gerek obje gerekse piksel tabanlı yaklaşımda EYK algoritmasının veri seti boyutundaki değişimlere ilişkin performansı genel olarak değerlendirildiğinde, obje tabanlı yaklaşımda en yüksek doğruluğa 10 bant ile piksel tabanlı yaklaşımda ise 20 bant ile ulaşabilmektedir. Bu sonuç veri seti boyutundaki artışların EYK algoritmasının performansını olumsuz etkilediğini ve az sayıda özellik kullanımıyla yüksek doğruluklara elde edilebildiğini göstermektedir.


### 6.1.2 Karar ağaçları algoritması

Obje tabanlı yaklaşımda kullanılan karar ağaçları (KA) algoritmasının veri seti boyutundaki artışa göre sınıflandırma performansı Şekil 6.3'de gösterilmiştir. Şekil incelendiğinde, veri seti boyutundaki artışla birlikte belirli bir noktaya kadar sınıflandırma doğruluğunun arttığı, bu kritik noktadan sonra hesaplanan doğrulukların azalma eğiliminde olduğu görülmektedir. KA sınıflandırıcısı için en yüksek sınıflandırma doğruluğu (%85,62) seçilen 40 özelliği içeren veri seti ile elde edilmiştir. En düşük doğruluk 75 özelliği içeren veri seti ile elde edilmiş olup, bu noktadan sonra sınıflandırma doğruluğunda bir miktar artış görülse de 40 özellik kullanılarak ulaşılan sonucun %3 gerisinde kalmıştır. Herhangi bir özellik seçimi kullanılmaksızın 216 özelliğin tamamını içeren veri seti KA ile sınıflandırıldığında elde edilen genel doğruluk %80,82'dir. Elde edilen bu sonuç özellik seçimi ile veri seti boyutunun %81 oranında azalmasına karşın KA algoritmasının sınıflandırma performansında %5 seviyelerinde artış olduğunu göstermektedir.



**Şekil 6.3 :** Obje tabanlı KA algoritmasının özellik boyutu değişimine göre sınıflandırma performansı.

KA algoritmasının piksel tabanlı yaklaşımda kullanılması durumunda veri seti boyutundaki değişimlere göre performansı analiz edildiğinde, sınıflandırma doğruluğunun seçilen ilk 40 bandın kullanımına kadar artış gösterdiği belirlenmiştir (Şekil 6.4). Bu kritik noktadan sonra hesaplanan doğruluklar yaklaşık %4 azalarak %80 seviyelerinde değerler almıştır. Çalışmada değerlendirmeye alınan 96 bantlı veri seti KA ile sınıflandırıldığında ulaşılan sınıflandırma doğruluk yine %80 seviyelerindedir.




**Şekil 6.4 :** Piksel tabanlı KA algoritmasının özellik boyutu değişimine göre sınıflandırma performansı.

Elde edilen sonuçlar, gerek obje gerekse piksel tabanlı yaklaşımda sınıflandırma algoritması olarak kullanılan karar ağacı algoritmasının sınıflandırma performansının veri seti boyutundaki değişimlere duyarlı olduğu, yüksek boyutlu veri setleri için düşük performans sergilediğini göstermektedir.


### 6.1.3 Destek vektör makineleri algoritması

Objeye tabanlı yaklaşımda segmente edilen görüntünün sınıflandırılmasında kullanılan destek vektör makinelerinin (DVM) veri seti boyutundaki değişimlere göre performansı Şekil 6.5’de gösterilmiştir. DVM’nin sınıflandırma performansı analiz edildiğinde veri seti boyutundaki artışa paralel olarak hesaplanan sınıflandırma doğruluğunun belirli bir seviyeye kadar yükseldiği, bu kritik noktadan sonra kullanılan bant sayısındaki artışın DVM’nin sınıflandırma performansını olumsuz etkilediği belirlenmiştir. DVM sınıflandırıcısı için en yüksek sınıflandırma doğruluğu (%93,84) 40 ve 50 özellik içeren veri setlerinin kullanılması durumunda elde edilmiştir. Ulaşılan bu sonuç 40 bantlı veri setine ilave edilecek 10 yeni bantın DVM sınıflandırma performansına herhangi bir katkı sağlamadığını göstermektedir. 50 battan sonra veri seti boyutundaki artışa paralel olarak DVM performansı azalan bir eğilim sergilemektedir. 216 özelliğin tamamını içeren veri seti DVM ile sınıflandırıldığında genel doğruluğun %91,09 olduğu belirlenmiştir. Sonuç olarak özellik seçimi ile veri seti boyutunun %81 oranında azalmasına karşın DVM’nin performansında %3 seviyelerinde artış olduğu tespit edilmiştir.



**Şekil 6.5 :** Objeye tabanlı DVM algoritmasının özellik boyutu değişimine göre sınıflandırma performansı.

Piksel tabanlı sınıflandırma işleminde DVM algoritmasının performansı veri seti boyutunda değişimler göz önüne alınarak incelendiğinde, bant sayısındaki artışa paralel olarak sınıflandırma performansının 40 özelliğin kullanımına kadar arttığı, bu kritik noktadan sonra veri setine eklenecek yeni özelliklerin sınıflandırma doğruluğu üzerinde olumlu bir etkisinin olmadığı tespit edilmiştir (Şekil 6.6). Herhangi bir özellik seçimi kullanılmaksızın 96 özelliğin tamamı DVM ile sınıflandırıldığında hesaplanan genel doğruluk %84,87’dir. Elde edilen sonuçlar, özellik seçimi ile veri seti boyutunun %60 oranında azalmasına karşın genel sınıflandırma doğruluğunda %3 seviyelerinde artış olduğunu göstermektedir.




**Şekil 6.6 :** Piksel tabanlı DVM algoritmasının özellik boyutu değişimine göre sınıflandırma performansı.

Literatürde DVM’nin Hughes fenomeni veya boyutsallık probleminden etkilenmediğini ifade eden çalışmalar olmasına karşın (Mercier ve Lennon, 2003; Gualtieri, 2009); yüksek boyutlu veri setleri için DVM’nin performansının olumsuz etkilendiğini belirten çalışmalar da bulunmaktadır (Guyon ve diğ, 2002; Gidudu ve Ruther, 2007). Bu nedenle literatürde özellik seçiminin DVM ile gerçekleştirilecek sınıflandırma işleminin doğruluğuna etkileri konusunda bir belirsizlik söz konusudur (Pal ve Foody, 2010). Tez kapsamında obje ve piksel tabanlı yaklaşımda ele alınan veri setleri için destek vektör makinelerinin veri seti boyutuna göre sınıflandırma performansının benzer özelliklerde olduğu görülmüştür. Her iki durumda da 40 özellikten sonra veri setindeki artışlar sınıflandırma performansını olumsuz etkilediği sonucuna ulaşılmıştır. Elde edilen bulgular, DVM’nin Hughes fenomeni veya boyutsallık probleminden etkilendiğini destekler niteliktedir.



#### 6.1.4 Rastgele orman algoritması


Obje tabanlı sınıflandırma yaklaşımında kullanılan rastgele orman (RO) algoritmasının veri seti boyutunda göre sınıflandırma performansındaki değişimler analiz edildiğinde, sınırlı sayıda özellik kullanıldığı durumlarda hesaplanan doğruluklarının düşük seviyelerde kaldığı tespit edilmiştir. Şekil 6.7’den de görüleceği üzere, özellik sayısının 50’den 75’e çıkması ile birlikte sınıflandırma doğruluğunda %3 artış olduğu görülmektedir. Bu kritik noktadan sonra sınıflandırma doğruluğunda belirli bir miktar düşüş gözlemlenmiş, 100, 150 ve 200 bandı içeren veri setleri için aynı sınıflandırma doğrulukları hesaplanmıştır. Herhangi bir özellik seçimi kullanılmaksızın 216 özelliğin tamamını içeren veri seti RO ile sınıflandırıldığında genel doğruluğun 75 veri seti ile elde edilen doğruluktan yaklaşık %3 daha düşük olduğu görülmüştür. Diğer bir ifadeyle özellik seçimi ile veri seti boyutunun %65 oranında azalmasına karşın genel sınıflandırma doğruluğunda %3 seviyelerinde artış olduğu ifade edilebilir.



Şekil 6.7 : Obje tabanlı RO algoritmasının özellik boyutu değişimine göre sınıflandırma performansı.

Piksel tabanlı sınıflandırma işleminin gerçekleştirilmesinde kullanılan RO algoritmasının veri seti boyutu ile ilgili performans değişimleri Şekil 6.8’de verilmiştir. Şekilde RO algoritmasının performansının kullanılan özellik sayısının 50’ye çıkarılana dek arttığı, bu noktadan sonra durağan bir davranış sergilediği görülmektedir. Bu kritik noktada hesaplanan doğruluk 96 özelliği içeren veri seti için hesaplanan doğruluktan %2 daha yüksektir.


Rastgele orman algoritmasının piksel ve obje tabanlı yaklaşımlarda sergilediği sınıflandırma performansı veri seti boyutu açısından ele alındığında, algoritmanın belirli bir seviyeden sonra sınıflandırma performansının değişmediği tespit edilmiştir. Dolayısıyla RO algoritmasının sınıflandırma performansı veri seti boyutuna duyarlı olduğu sonucuna ulaşılmıştır.



**Şekil 6.8 :** Piksel tabanlı RO algoritmasının özellik boyutu değişimine göre sınıflandırma performansı.


### 6.1.5 Torbalama algoritması

Objeye tabanlı yaklaşımda kullanılan torbalama algoritmasının performansı kullanılan veri seti boyutuna göre analiz edildiğinde, algoritmanın veri seti boyutundaki değişimlere duyarlı olduğu tespit edilmiştir. Şekil 6.9’den de görüleceği üzere özellik sayısındaki artışlar algoritmanın performansında ani değişikliklere neden olabilmektedir. Örneğin kullanılan özellik sayısı 10’dan 20’ye çıkarıldığında sınıflandırma doğruluğu %3’e varan seviyelerde artarken, özellik sayısı 20’den 30’a çıktığında doğruluk %2 azalmaktadır. Genel olarak seçilen 40 banttan sonra veri setine eklenecek diğer bantların sınıflandırma doğruluğunda azalmaya neden olduğu ifade edilebilir. Herhangi bir özellik seçimi kullanılmaksızın 216 özelliğin tamamını içeren veri seti torbalama algoritması ile sınıflandırıldığında genel doğruluğun %84,93 olduğu ve seçilen 40 veri seti ile elde edilen doğruluktan yaklaşık %3 daha düşük olduğu tespit edilmiştir.



**Şekil 6.9 :** Obj e tabanlı torbalama algoritmasının özellik boyutu de ğ iř imine g ö re sınıflandırma performansı.

Torbalama algoritmasının piksel tabanlı yaklaşımda kullanılması durumunda, veri seti boyutuna g ö re sınıflandırma performansı Ş ekil 6.10’da g ö r ö l m e k t e d i r . Ş ekil incelendi ğ inde 10, 20 ve 30 özelli ğ i i ç eren veri setleri ile torbalama algoritmasının y ü k s e k sınıflandırma d o ğ r u l u k l a r ı n a u l a ř t ı ğ ı g ö r ö l m e k t e d i r . Bunlar i ç erisinde en y ü k s e k d o ğ r u l u k (%83,59) se ç ilen 30 özelli ğ i i ç eren veri seti ile elde edilmiř tir. Bu kritik noktadan sonra torbalama algoritmasının sınıflandırma d o ğ r u l u ğ u azalma e ğ i l i m i n d e d i r . Veri setleri i ç erinde en d ü ř ü k sınıflandırma d o ğ r u l u ğ u t ü m bantları i ç eren veri seti kullanımı ile elde etmiř tir.




**Ş ekil 6.10 :** Piksel tabanlı torbalama algoritmasının özellik boyutu de ğ iř imine g ö re sınıflandırma performansı.

Torbalama algoritmasının piksel ve obje tabanlı yaklaşımlarda sergilediği sınıflandırma performansları bir arada değerlendirildiğinde, genel olarak algoritmanın kullanılan veri seti boyutunun algoritmanın performansını belirleyen önemli bir etken olduğu ifade edilebilir.


### 6.1.6 Hızlandırma algoritması

Obje tabanlı yaklaşımda kullanılan hızlandırma algoritmasının performansı veri seti boyutundaki artışa göre analiz edildiğinde genel olarak seçilen 100 banttan sonra veri setine eklenecek diğer bantların sınıflandırma doğruluğunda önemli bir artışa neden olmadığı görülmüştür (Şekil 6.11). 100 özellik kullanımıyla için elde edilen sınıflandırma doğruluğu 75 özelliği içeren veri setine göre %0,68 daha iyi sonuç vermesine rağmen söz konusu fark ihmal edilebilir niteliktedir.



**Şekil 6.11 :** Objeye tabanlı hızlandırma algoritmasının özellik boyutu değişimine göre performansı.


Piksel tabanlı sınıflandırma işleminde hızlandırma algoritmasının performansı veri seti boyutundaki artışa göre değerlendirildiğinde genel olarak seçilen 30 banttan sonra veri setine eklenecek diğer bantların sınıflandırma doğruluğunda önemli derecede azalmaya neden olduğu ifade edilebilir (Şekil 6.12). Elde edilen tüm sonuçlar hızlandırma algoritmasının da gerek piksel gerekse obje tabanlı yaklaşımda kullanılması durumunda sınıflandırmada dikkate alınacak veri seti boyutuna duyarlı olduğunu göstermektedir. Diğer bir ifadeyle veri seti boyundaki değişimler algoritmanın performansında ani artış veya azalmaya neden olabilmektedir.



**Şekil 6.12 :** Piksel tabanlı hızlandırma algoritmasının özellik boyutu değişimine göre performansı.

#### 6.1.7 Çoklu hızlandırma algoritması


Piksel tabanlı çoklu hızlandırma algoritmasının veri seti boyutundaki değişimlere göre performansı Şekil 6.13’de verilmiştir. Şekil incelendiğinde, algoritmanın performansının veri seti boyutuna oldukça duyarlı olduğu ve veri seti boyutundaki değişimlerin sınıflandırma doğruluğunda artı ya da eksi yönde etkilediği görülmektedir. Genel olarak seçilen 75 banttan sonra veri setine eklenecek diğer bantların sınıflandırma doğruluğunda bir atışa neden olmadığı söylenebilir.



**Şekil 6.13 :** Obje tabanlı çoklu hızlandırma algoritmasının özellik boyutu değişimine göre performansı.

Çoklu hızlandırma algoritması ile elde edilen en yüksek sınıflandırma doğruluğuna (%90,41) 75 ve 150 özellik içeren veri setlerinin kullanıldığında ulaşılmıştır. Bu bulgu veri seti içerisine sonradan dahil edilen 75 özelliğin sınıflandırma doğruluğunu değiştirmediğini göstermektedir. Görüntü objeleri için tanımlanan 216 özelliğin tamamı sınıflandırıldığında elde edilen genel doğruluk %89,73'tür. Bu sonuç özellik seçimi ile veri seti boyutu %65 azalmasına karşın genel sınıflandırma doğruluğunda %1 seviyelerinde artış olduğu göstermektedir.

Piksel tabanlı yaklaşımda çoklu hızlandırma algoritmasının sınıflandırma performansı dikkate alınan veri seti boyutuna göre analiz edildiğinde 10, 20 ve 30 bantı içeren veri setleri ile yüksek sınıflandırma doğruluklarının elde edildiği Şekil 6.14'de görülmektedir. Bunlar içerisinde en yüksek doğruluk (%84,46) 30 bantlı veri seti ile elde edilmiştir. Bu kritik noktadan sonra algoritmanın sınıflandırma doğruluğu azalma eğilimi göstermektedir. Diğer taraftan çoklu hızlandırma algoritması için hesaplanan en düşük sınıflandırma doğruluğu tüm özellikleri içeren veri setinin kullanılmasıyla elde edildiği tespit edilmiştir.




**Şekil 6.14 :** Piksel tabanlı çoklu hızlandırma algoritmasının özellik boyutu değişimine göre performansı.

### 6.1.8 Rotasyon orman algoritması

Obje tabanlı rotasyon orman (RotOR) algoritmasının veri seti boyutundaki artışa göre sınıflandırma performansı Şekil 6.15'den de görüleceği üzere özellik sayısındaki artışa paralel olarak sınıflandırma performansı belirli bir seviyeye kadar yükselmektedir. Bu kritik noktadan sonra özellik sayısındaki artışın RotOR


algoritmasının sınıflandırma performansını negatif olarak etkilediği görülmektedir. RotOR için en yüksek sınıflandırma doğruluğu (%94,52) özellik seçimi ile tespit edilen en iyi 50 özelliği içeren veri seti ile elde edildiği belirlenmiştir. Herhangi bir özellik seçimi kullanılmaksızın 216 özelliğin tamamını içeren veri seti RotOR ile sınıflandırıldığında elde edilen genel doğruluğun %91,84 olduğu ve en yüksek doğruluktan yaklaşık %3 daha düşük olduğu görülmüştür.



**Şekil 6.15 :** Obje tabanlı RotOR algoritmasının özellik boyutu değişimine göre sınıflandırma performansı.

Piksel tabanlı sınıflandırma işleminde kullanılan rotasyon orman algoritmasının sınıflandırma performansı veri seti boyutundaki artışa göre analiz edildiğinde, Şekil 6.16'dan da görüleceği veri boyutundaki değişimlere duyarlıdır. Genel olarak ele alındığında 30 özellikten sonra özellik sayısındaki artışların hesaplanan sınıflandırma doğruluğunda önemli bir değişiklik ortaya çıkarmadığı görülmüştür. Özellik seçimi kullanılmadığında tüm veri seti için hesaplanan doğruluk 30 özelliikle elde edilen doğruluktan %3 daha düşüktür. RotOR algoritmasının piksel ve obje tabanlı yaklaşımlarda kullanımı sonucunda elde edilen bulgular, algoritmanın veri seti boyutu değişimlerine duyarlı olduğunu göstermektedir.

Veri seti boyutundaki değişimler ile ilgili gerçekleştirilen analizler ve incelemeler neticesinde, tez kapsamında değerlendirmeye alınan sınıflandırma algoritmalarının tamamının veri seti boyutuna duyarlı olduğu görülmüştür. Diğer bir ifadeyle algoritmaların sınıflandırma performansı kullanılacak veri seti boyutuna göre değişkenlik göstermektedir.



**Şekil 6.16 :** Piksel tabanlı RotOR algoritmasının özellik boyutu değişimine göre sınıflandırma performansı.

## 6.2 Sınıflandırma Algoritmalarının Karşılaştırılması ve Analizi

Tez kapsamında sınıflandırma ve tematik harita üretiminde birçoğu literatürde ileri sınıflandırma tekniği olarak adlandırılan 8 farklı algoritma kullanılmıştır. Gerek piksel gerekse obje tabanlı sınıflandırma yaklaşımında temel sınıflandırıcı olarak değerlendirmeye alınmış, farklı boyutlarda ve içerikte veri setleri için sınıflandırma performansları analiz edilmiştir. Bu bölümde ele alınan performans analizleri ve karşılaştırmalarda algoritmaların özellik seçimi ile ulaştıkları en yüksek sınıflandırma doğrulukları esas alınmış ve bu genel doğruluklar üzerinden değerlendirmeler gerçekleştirilmiştir. Analizlerin gerçekleştirilmesinde WV-2 uydu görüntüsünün 8 spektral bandını temsil eden ortalama değerler ve 216 banttan oluşan veri setleri de değerlendirmeye alınarak, tezde önerilen özellik seçimi yaklaşımının etkinliği araştırılmıştır. Bu amaçlar doğrultusunda, sınıflandırma algoritmalarının öncelikli olarak obje ve piksel tabanlı yaklaşımlarda sergiledikleri performanslar ayrı ayrı analiz edilmiş, her iki yaklaşımdaki performanslar karşılaştırılarak obje ve piksel tabanlı yaklaşımların problem çözümündeki etkinliği ortaya koyulmuştur.

### 6.2.1 Obje tabanlı yaklaşım için performans analizi


Obje tabanlı yaklaşımda kullanılan sınıflandırma algoritmalarının performansı Şekil 6.17’de gösterilmiştir. Şekil incelendiğinde karar ağaçları (KA) dışındaki tüm algoritmaların en düşük sınıflandırma doğruluklarını WV-2 uydu görüntüsünün



multispektral bantları kullanımıyla elde ettikleri görülmektedir. Diğer taraftan uydu görüntüsünün yardımcı verilerle beraber kullanıldığında KA dışındaki tüm algoritmaların sınıflandırma performanslarında %2'ye varan artışlar olduğu tespit edilmiştir. Bu bulgu, yardımcı verilerin segmentasyon sonucu oluşan görüntü objelerinin birbirinden ayırt edilmesi ve sınıflandırma doğruluğunun artırılması noktasında önemli bir kaynak olduğunu göstermektedir.

Obje tabanlı yaklaşımda hesaplanan sınıflandırma sonuçları algoritmalarının performansları açısından analiz edildiğinde, WV-2 bantları kullanılarak hesaplanan en yüksek doğruluğun %90,41 olarak RotOR algoritmasıyla elde edildiği görülmektedir. Bununla birlikte RO algoritması RotOR algoritması ile benzer bir performans göstererek %89,73 doğruluğa ulaşmıştır. Algoritmalar içerisinde en düşük sınıflandırma doğruluğunun ise KA ve EYK algoritmaları ile %80,14 olarak hesaplandığı görülmektedir. 216 bantlı tüm veri seti için algoritmaların sergilediği performanslar incelendiğinde, en yüksek sınıflandırma doğruluğunun %91,10 ile RO algoritmasıyla elde edildiği görülmektedir. RotOR algoritması tüm veri seti için RO algoritmasına benzer bir performans sergileyerek %90,84 doğruluğa ulaşmıştır. Bu veri seti için en düşük doğruluk %76,03 ile KA algoritması için hesaplanmıştır. Özellik seçimi sonucunda elde edilen veri setlerinin kullanımı durumunda ise en yüksek doğruluk %94,52 ile RotOR algoritması için elde edilirken, DVM için benzer sınıflandırma doğruluğuna ulaşılmıştır. Bu veri setleri için elde edilen performanslar içerisinde en düşük doğruluk %85,62 ile KA algoritmasına aittir.

Obje tabanlı yaklaşımda kullanılan algoritmaların sınıflandırma sonuçları bir bütün olarak ele alındığında, RotOR, DVM ve RO algoritmalarının değerlendirmeye alınan diğer algoritmalarla göre daha başarılı olduğu sonucuna ulaşılmıştır. Özellikle RotOR ve DVM algoritmaları özellik seçimi sonucu elde edilen veri setleriyle, obje tabanlı yaklaşımda standart sınıflandırma algoritması olarak kabul edilen EYK algoritmasına göre yaklaşık %7 ve RO algoritmasına göre %3 daha yüksek sınıflandırma doğruluğu üretmiştir. Bu nedenle, tez kapsamında obje tabanlı yaklaşımla veri setinin sınıflandırılması ve arazi örtüsü/kullanımını temsil eden tematik harita üretiminde söz konusu algoritmalarla ait sınıflandırma modelleri esas alınmıştır.



**Şekil 6.17 :** Obje tabanlı yaklaşım kullanılarak elde edilen sınıflandırma sonuçları.


### 6.2.2 Piksel tabanlı yaklaşım için performans analizi

Piksel tabanlı yaklaşımda sınıflandırma algoritmaları için hesaplanan genel doğruluklar Şekil 6.18’de gösterilmiştir. Şekil incelendiğinde EYK ve KA dışındaki tüm algoritmaların, WV-2 uydu görüntüsünün 8 bantı ve tüm özellikleri içeren 96 bantlı veri seti kullanımında benzer sınıflandırma performansları sergiledikleri görülmektedir. Diğer bir ifadeyle WV-2 görüntüsüne ilave edilen yardımcı verilerin tamamı piksel tabanlı sınıflandırma işlemine tabi tutulduğunda EYK ve KA haricindeki algoritmaların sınıflandırma performanslarında önemli bir artış görülmemiştir.

Şekilden de görüleceği üzere değerlendirmeye alınan en düşük ve en yüksek boyutlu veri setleri (8 bant ve 96 bant) kullanıldığında, en yüksek sınıflandırma doğruluklarının (%85,49 ve %84,87) DVM algoritması ile elde edildiği görülmektedir. EYK ve KA algoritmaları bu veri setleri için %80 seviyelerinde doğruluğa ulaşırken, diğer algoritmalar için hesaplanan doğruluklar %84 seviyelerindedir. Bu veri setleri için hesaplanan en düşük doğruluk (%78,97) KA algoritmasıyla 96 bantlı verinin sınıflandırılması sonucunda elde edilmiştir.

Şekil 6.18’den de görüleceği üzere, sınıflandırma performanslarının özellik seçimiyle elde edilen veri setleri kullanarak 8 bantlı veri seti kullanımına göre %4 seviyelerinde arttığı görülmektedir. Aynı şekilde 96 bantlı veri setinin kullanılması yerine özellik seçimi yaklaşımıyla sınıflandırma doğruluğunda %4 seviyelerinde artış görülmüştür.


Özellik seçimi ile belirlenen veri setleri kullanımıyla piksel tabanlı sınıflandırma algoritmaları içerisinde en yüksek sınıflandırma doğruluğu DVM ile %88,23 olarak hesaplanmıştır. Bununla birlikte RotOR ve RO algoritmaları ile elde edilen doğrulukların %86 seviyelerinde olduğu, diğer algoritmaların ise %84 seviyelerinde sınıflandırma performansı sergilediği görülmüştür. Bu açıdan ele alındığında piksel tabanlı sınıflandırma işleminin gerçekleştirilmesinde DVM, RotOR ve RO algoritmalarının diğer algoritmalarından daha başarılı olduğu söylenebilir.



**Şekil 6.18 :** Piksel tabanlı yaklaşım kullanılarak elde edilen sınıflandırma sonuçları.


### 6.2.3 Obje ve piksel tabanlı yaklaşımların karşılaştırılması ve analizi

Sınıflandırma algoritmalarının piksel ve obje tabanlı yaklaşımlardaki performanslarının detaylı olarak analizinin ardından sonuçlar bir arada değerlendirilerek yaklaşımların sınıflandırma işlemindeki etkinliği ve algoritmaların kullanılan yaklaşıma göre performansları ortaya koyulmuştur. Bu amaç doğrultusunda, ilk olarak WV-2'nin 8 spektral bandını içeren veri setinin sınıflandırma sonuçları karşılaştırılmıştır. Söz konusu veri seti göz önüne alındığında Şekil 6.19'dan da görüleceği üzere EYK ve KA algoritmalarının gerek piksel ve gerekse obje tabanlı sınıflandırmada aynı sınıflandırma performansı sergilediği görülmektedir. Diğer algoritmaların ise obje tabanlı yaklaşımla daha yüksek sınıflandırma doğruluğuna ulaştıkları şekilde de açıkça görülmektedir. Sınıflandırma algoritmaları içerisinde özellikle RO ve RotOR algoritmalarının obje tabanlı yaklaşımla sınıflandırma performanslarının piksel tabanlı sınıflandırmaya göre %6 seviyelerinde arttığı görülmektedir. Diğer taraftan DVM, TRB, HIZ ve ÇH algoritmalarının performanslarındaki artışın %2 seviyelerinde gerçekleştiği belirlenmiştir.




Şekil 6.19 : WV-2 uydu görüntüsü kullanılarak hesaplanan sınıflandırma doğrulukları.

WV-2 ve yardımcı verilerin entegrasyonu ile elde edilen yüksek boyutlu veri setleri herhangi bir özellik seçimi yapılmaksızın obje ve piksel tabanlı yaklaşımla sınıflandırıldığında elde edilen sonuçlar Şekil 6.20’de gösterilmiştir. KA ve EYK haricindeki diğer tüm algoritmaların obje tabanlı sınıflandırma yaklaşımı ile daha yüksek doğruluklara ulaştığı belirlenmiştir. Şekilden de görüleceği üzere her iki yaklaşımda da en düşük sınıflandırma doğruluğuna EYK ve KA algoritmaları ile ulaşıldığı görülmektedir. KA algoritması obje tabanlı sınıflandırma işleminde dikkate alınan 216 özelliğe sahip veri seti kullanımıyla diğer algoritmalar içerisinde en düşük sınıflandırma doğruluğuna ulaşmıştır. KA algoritmasının piksel tabanlı sınıflandırmada dikkate alınan 96 özelliği içeren veri seti ile daha yüksek sınıflandırma doğruluğuna ulaşmasının, algoritmanın veri seti boyutuna karşı duyarlılığının bir sonucu olduğu ifade edilebilir. Bu veri seti için, obje tabanlı yaklaşımla diğer sınıflandırma algoritmalarının performansında RO, ÇH ve RotOR için %7, DVM için %5, ÇH ve TRB algoritmaları için %2 seviyelerinde iyileşmeler olduğu tespit edilmiştir.



**Şekil 6.20 :** WV-2 ve yardımcı veri setleri kullanılarak hesaplanan sınıflandırma doğrulukları.

Tez kapsamında önerilen özellik seçimi yaklaşımı ile oluşturulan veri setleri içerisinde algoritmaların obje ve piksel tabanlı yaklaşımda ulaştığı en yüksek sınıflandırma doğrulukları Şekil 6.21’de sunulmuştur. Sonuçlar analiz edildiğinde, obje tabanlı yaklaşımla tüm sınıflandırma algoritmalarının daha yüksek doğruluklara ulaştığı görülmektedir. Özellik seçimi sonucunda elde edilen veri setleri ile RotOR algoritması piksel tabanlı yaklaşıma göre %8 daha yüksek sonuç elde ederken; DVM, RO ve ÇH algoritmalarının sınıflandırma performansı %5 seviyelerinde artış göstermiştir. Diğer algoritmalar için sınıflandırma doğruluğundaki bu iyileşme oranı %3 seviyelerinde kalmıştır.



**Şekil 6.21 :** Özellik seçimi ile belirlenen veri setleri için hesaplanan sınıflandırma doğrulukları.

Obje ve piksel tabanlı yaklaşımlar ve algoritmaların performansları üzerine gerçekleştirilen analiz sonuçları genel olarak ele alındığında önemli bulgulara ulaşılmıştır. Bunlardan ilki, tez kapsamında ele alınan sınıflandırma problemin çözümünde obje tabanlı yaklaşımın benzer spektral özelliklere sahip nesnelerin ayırt edilmesi noktasında piksel tabanlı yaklaşıma göre daha başarılı olduğudur. İkinci olarak değerlendirmeye alınan ileri sınıflandırma algoritmalarının obje tabanlı yaklaşımda kullanımıyla problem çözümündeki etkinliği ortaya koyulmuştur. Bu

algoritmalar içerisinde özellikle DVM, RotOR ve RO algoritmaları gerek WV-2 görüntüsü, gerek yüksek boyutlu veri setleri gerekse özellik seçimi ile belirlenen veri setleri kullanımında üstün sınıflandırma performansı sergileyerek diğer algoritmalar içerisinde öne çıkmıştır.

### **6.3 Özellik Seçimi Algoritmalarının Karşılaştırılması ve Analizi**

Tez kapsamında özellik seçimi ve boyut azaltılması amacıyla 13 farklı algoritma kullanılmıştır. Bu algoritmalarından 6'sı istatistiksel tabanlı olup diğer 7 tanesi son birkaç yıldır kullanılmaya başlayan güncel özellik seçimi algoritmalarından oluşmaktadır. Söz konusu algoritmalar kullandıkları istatistiksel veya kavramsal ölçütler yardımıyla eğitimde kullanılacak veri setini esas alarak değerlendirmeye alınan özelliklerin sınıflandırma doğruluğuna etkilerine göre önem derecesini belirlemektedir. Algoritmaların kullandıkları değerlendirme ölçütleri farklı olduğundan özellik seçimi sonucu farklı derecelendirmeler ortaya çıkmaktadır. Diğer bir ifadeyle 13 özellik seçimi algoritması ile orijinal veri setinin 13 farklı bant kombinasyonu elde edilebilmektedir. Örneğin görüntü objeleri için tanımlanan 216 özellik, özellik seçimi algoritmaları tarafından değerlendirerek veri seti içerisindeki her bir özelliğin önem derecesi belirlenmiştir. Sonuçta 216 özelliğin 13 farklı kombinasyonu veya özelliklerin önem sırasının değişiklik gösterdiği 13 farklı bant dizilişi elde edilmiştir. Örneğin ki-kare testi ile kırmızı bandın ortalama değeri en önemli özellik olarak belirlenirken, t-testi ile kızılötesi-1 bandının ortalama değeri en önemli özellik olarak derecelendirilmiştir.

Tezin bu bölümünde özellik seçimi algoritmalarının karşılaştırılması ve analizi iki temel başlık altında ele alınmıştır. Bunlardan ilki özellik seçimi algoritmalarının belirlediği bant kombinasyonları için sınıflandırma algoritmalarının performanslarının incelenmesidir. Bu analizler neticesinde en yüksek sınıflandırma doğruluğunun elde edildiği veri seti ve söz konusu veri setinin oluşturulmasında kullanılan özellik seçimi algoritmaları ortaya koyulabilecektir. Bunun yanında sınıflandırma algoritmalarının en yüksek doğruluğa ulaştığı optimum veri seti boyutları incelenerek, özellik seçimi algoritmalarınca önem derecesine göre sıralanan özelliklerin ne kadarının en yüksek sınıflandırma doğruluğuna ulaşmakta yeterli olduğu tespit edilebilecektir. İkinci başlık altında en yüksek sınıflandırma doğruluğuna ulaşılan veri seti içerisindeki özellikler analiz edilmesidir.



Gerçekleştirilen analizler neticesinde, WV-2 görüntüsün spektral bantlarının, vejetasyon indekslerinin, temel bileşenlerin ve doku özelliklerinin sınıflandırma doğruluğu üzerindeki etkileri ortaya koyulabilmektedir. Diğer bir ifadeyle hangi özelliklerin benzer spektral özelliklere sahip yeryüzü nesnelerinin birbirinden ayırt edilmesi noktasında etkili olduğu tespit edilebilecektir.

### 6.3.1 Özellik seçimi algoritmalarının karşılaştırılması ve analizi

Özellik seçimi algoritmalarının sınıflandırma performansı üzerine etkilerinin karşılaştırması ve analizinde, obje ve piksel tabanlı yaklaşımlarda elde edilen sonuçlar ilk önce kendi içerisinde daha sonra bir arada değerlendirilmiştir. Özellik seçimi algoritmalarının ve optimum veri seti boyutunun analizi amacıyla ilk olarak obje tabanlı sınıflandırma işleminde hesaplanan en yüksek sınıflandırma doğrulukları göz önüne alınarak Çizelge 6.1 oluşturulmuştur. Çizelgeden de görüleceği obje tabanlı yaklaşımda sınıflandırma algoritmalarının %50'si DVM-ÖÖE algoritması tarafından seçilen özellikler kullanılarak en yüksek doğruluğa ulaşmıştır. Oje tabanlı sınıflandırmada en yüksek doğruluğa ulaşmada etkili olan diğer özellik seçim algoritmalarının ise OneR, InfoG ve t-test algoritmaları olduğu görülmüştür.

**Çizelge 6.1 :** Obje tabanlı yaklaşımda özellik seçimi algoritmalarının ve optimum bant sayılarının analizi.

| Sınıflandırıcı | Bant Sayısı | Algoritma | Doğruluk (%) |
|----------------|-------------|-----------|--------------|
| RotOR          | 50          | DVM-ÖÖE   | 94,52        |
| DVM            | 40          | DVM-ÖÖE   | 93,86        |
| RO             | 75          | DVM-ÖÖE   | 91,78        |
| ÇH             | 75          | T-test    | 90,41        |
| HIZ            | 75          | DVM-ÖÖE   | 89,73        |
| EYK            | 10          | InfoG     | 87,67        |
| TRB            | 40          | OneR      | 86,30        |
| KA             | 40          | OneR      | 85,62        |

Obje tabanlı yaklaşımda kullanılan sınıflandırıcıların performansları özellik seçiminde kullanılan algoritmalar açısından ele alındığında en yüksek üç sınıflandırma doğruluğunun (%94,52, %93,86 ve %91,78) RotOR, DVM ve RO sınıflandırıcılarıyla DVM-ÖÖE algoritmasıyla seçilen özellik kombinasyonları kullanılarak elde edildiği görülmektedir. RotOR algoritması en yüksek sınıflandırma doğruluğuna DVM-ÖÖE ile belirlenen en iyi 50 özellik ile ulaşırken, DVM algoritması 40 özellekle sonuca ulaşmıştır. Bunlar dışında RO ve HIZ algoritmalarının DVM-ÖÖE algoritması tarafından seçilen 75 özellekle en yüksek

doğruluğa ulaştığı görülmektedir. Çizelgede en düşük sınıflandırma doğruluklarının OneR algoritması tarafından seçilen 40 özelliği kullanarak KA ve TRB sınıflandırıcıları ile elde edildiği görülmektedir.

Piksel tabanlı sınıflandırmada özellik seçimi algoritmalarının etkinliği ve optimum veri seti boyutunun analizi amacıyla oluşturulan Çizelge 6.2’de, sınıflandırıcıların en yüksek doğruluğa ulaştığı veri seti boyutu ve özellik seçimi algoritması bir arda gösterilmiştir. Çizelgeden de görüleceği üzere en yüksek iki sınıflandırma doğruluğu (%88,23 ve %86,72) DVM ve RotOR sınıflandırıcılarıyla DVM-ÖÖE özellik seçimi algoritması tarafından belirlenen bantlar kullanılarak elde edilmiştir. DVM algoritması bu doğruluğa 40 özelliği içeren veri seti ile ulaşırken, RotOR algoritması seçilen 30 özelliikle en yüksek doğruluğa ulaşmıştır.


**Çizelge 6.2 :** Piksel tabanlı yaklaşımda özellik seçimi algoritmalarının ve optimum bant sayılarının analizi.

| Sınıflandırıcı | Bant Sayısı | Algoritma | Doğruluk (%) |
|----------------|-------------|-----------|--------------|
| DVM            | 40          | DVM-ÖÖE   | 88,23        |
| RotOR          | 30          | DVM-ÖÖE   | 86,72        |
| RO             | 50          | RF        | 86,41        |
| ÇH             | 30          | ReliefF   | 84,46        |
| HIZ            | 30          | ReliefF   | 84,41        |
| EYK            | 20          | DVM-ÖÖE   | 83,74        |
| TRB            | 30          | GainR     | 83,59        |
| KA             | 40          | DVM-ÖÖE   | 83,18        |

Piksel tabanlı sınıflandırma algoritmaları içerisinde en iyi üçüncü sınıflandırma doğruluğunu elde eden RO algoritması, RF algoritmasının belirlediği 50 bantlı veri setiyle elde etmiştir. Piksel tabanlı sınıflandırma algoritmaları içinde en düşük doğruluğa sahip KA algoritması DVM-ÖÖE ile seçilen 40 bantlı veri seti ile ancak bu doğruluğa ulaşabilmiştir. EYK algoritması da sınıflandırdığı 13 farklı veri seti içerisinde DVM-ÖÖE ile seçilen 20 özellik ile en yüksek sınıflandırma performansını göstermiştir. ÇH ve HIZ algoritmalarının ulaştığı en yüksek doğruluk ReliefF ile seçilen 30 özelliğin kullanımıyla elde edilmiş ve iki algoritma söz konusu veri setiyle aynı sınıflandırma performansını sergilemiştir. TRB sınıflandırıcısı GainR algoritması tarafından seçilen 30 özelliği kullanarak kendi içerisindeki en yüksek sınıflandırma doğruluğa ulaşabilmiştir.

Obje ve piksel tabanlı yaklaşımlar için elde edilen sonuçların bir arada analiz edilmesi amacıyla, hesaplanan en yüksek sınıflandırma doğruluklarının elde


edilmesinde kullanılan özellik seçimi algoritmalarının kullanım sıklığı belirlenmiş ve Şekil 6.22’de sunulmuştur. Şekilden de görüleceği üzere tez kapsamında değerlendirmeye alınan 13 özellik seçimi algoritması içerisinde en çok DVM-ÖÖE ile seçilen özelliklerle en yüksek doğruluklara ulaşmıştır. Diğer bir ifadeyle hem piksel tabanlı hem de obje tabanlı sınıflandırmada değerlendirmeye alınan sınıflandırma algoritmalarının %50’si en yüksek sınıflandırma doğruluğuna DVM-ÖÖE ile üretilen veri seti ile ulaşmıştır. Diğer taraftan, OneR ve ReliefF algoritmaları ile belirlenen özellikler toplamda 2, GainR, InfoG ve t-test algoritmaları sadece 1 kez en yüksek doğruluğu veren özellikleri tespit etmişleridir. Diğer taraftan ChiSq, Fisher, NaiveB, Pearson, ProbSig ve SymtUnc algoritmalarının belirlediği özellik kombinasyonlarıyla ne piksel ne de obje tabanlı sınıflandırmada en yüksek doğruluğa ulaşamadığı görülmektedir.



**Şekil 6.22 :** Obje ve piksel tabanlı sınıflandırmada özellik seçimi algoritmaların kullanım sıklığının analizi.

Obje ve piksel tabanlı sınıflandırmada hesaplanan en yüksek sınıflandırma doğrulukları kullanılan bant sayıları açısından analiz edildiğinde (Şekil 6.23), genel olarak tüm sınıflandırılma algoritmalarının 30, 40 veya 50 özelliği içeren veri setleri ile sonuca ulaştıkları tespit edilmiştir. Piksel tabanlı sınıflandırma işleminde en yüksek sınıflandırma doğruluğuna ulaşılan DVM, DVM-ÖÖE ile seçilen 40 özellikle sonuca ulaşırken, obje tabanlı yaklaşımda RotOR algoritması 50 özelliği kullanarak

sonuca ulaşmıştır. Şekilden de görüleceği üzere hiçbir algoritma 90, 100, 150 ve 200 gibi yüksek boyutlu veri setleri kullanılarak yüksek sınıflandırma doğruluğu elde etmemiştir. Özellik seçimi algoritmalarının sınıflandırma performansı üzerindeki etkileri ile ilgili elde edilen bu sonuçlar, tez kapsamında önerilen özellik seçimi yaklaşımının etkinliğini gösterirken, değerlendirmeye alınan tüm sınıflandırma algoritmalarının veri seti boyutuna duyarlı olduğunu destekler niteliktedir. Diğer bir ifadeyle uygun bir özellik seçimi yaklaşımıyla veri seti boyutunun önemli derecede azaltılarak, sınıflandırma performansı önemli derecede artırılabilir.



Şekil 6.23 : Objeye ve piksel tabanlı sınıflandırmada özellik boyutunun analizi.

### 6.3.2 Özellik seçimi ile belirlenen özelliklerin (bantların) analizi

Özellik seçiminde kullanılan algoritmaların ve optimum özellik boyutunun değerlendirilmesinin ardından, tezin bu bölümünde objeye ve piksel tabanlı yaklaşımda en yüksek sınıflandırma doğruluğuna ulaşılan veri seti içerisindeki özellikler değerlendirilmeye alınmıştır. Gerek objeye gerekse piksel tabanlı sınıflandırmada özellik seçimi sonucunda elde edilen veri setleri içerisinde en yüksek sınıflandırma doğruluklarının DVM-ÖÖE ile seçilen en iyi 30, 40 ve 50 özellikle elde edildiği tespit edilmiştir. Bu nedenle seçilen özelliklerin analizinde DVM-ÖÖE ile belirlenen en iyi 50 özellik esas alınmış ve sınıflandırma sonuçlarına olan katkıları analiz edilmiştir.

Obje tabanlı sınıflandırma işleminde segmentasyon işlemi sonucunda üretilen görüntü objelerinin temel spektral özellikleri (ortalama, maksimum, minimum, standart sapma, maksimum fark, orana ve HSI dönüşümü) ve doku özelliklerinden oluşan toplam 216 özelliği içeren veri seti özellik seçimine tabi tutulmuştur. Çizelge 6.3’de söz konusu yüksek boyutlu veri seti içerisinde DVM-ÖÖE algoritması ile seçilen 50 özelliğe ait puanlamalar ve özelliklerin önem sıralamaları gösterilmiştir. Çizelgede verilen özellikler temel spektral özellikler ve doku özellikleri olarak iki genel özellik ölçütü altında incelenmiş ve analiz edilmiştir.


Obje tabanlı sınıflandırma işleminin gerçekleştirilmesinde DVM-ÖÖE ile seçilen en iyi 50 özellik analiz edildiğinde, veri seti içerisindeki özelliklerin 47 tanesinin görüntü objeleri için tanımlanan temel spektral özelliklerden oluştuğu, doku özelliklerinden sadece 7 tanesinin ilk 50 özellik içerisinde girebildiği görülmektedir. Elde edilen bu ilk bulgu obje tabanlı sınıflandırma işleminde görüntü objeleri için tanımlanacak temel spektral özelliklerin sınıflandırma doğruluğu üzerinde etkili olduğunu gösterir niteliktedir. Temel spektral özellikler kullanılan özellik ölçütü açısından analiz edildiğinde, objelerin 11 banttaki minimum değerlerinin en fazla kullanılan özellik ölçütü olduğu görülmektedir. Görüntü objelerinin 9 banttaki ortalama değerleri ve HSI dönüşümü sonucunda elde edilen 9 bileşenin diğer ölçütlere göre daha yüksek puanlar aldığı görülmektedir. Diğer taraftan standart sapma ve maksimum fark ölçütlerinin ise en az tercih edilen özellik ölçütü olduğu görülmektedir.

Çizelge 6.3 seçilen özellikler açısından ele alındığında obje tabanlı sınıflandırma için en yüksek puan alan özellik kırmızı, yeşil ve mavi bantların HSI dönüşümünde kullanımı sonucunda hesaplanan renk tonu (Hue) bileşenidir. Sıralamada ikinci sıradaki ölçütün, görüntü objelerinin kızlötesi-2 bandındaki ortalama değerleri olduğu görülmektedir. Bunun yanında, objeler için WV-2 görüntüsünün kızlötesi-2 ve kırmızı kenar bantları kullanılarak hesaplanan NDVI-3 bandındaki ortalama değerlerin DVM-ÖÖE algoritması tarafından seçilen en iyi üçüncü özellik olduğu belirlenmiştir. Diğer taraftan sıralamada en sonda yer alan özellikler kızlötesi-1, kırmızı ve yeşil bantlar yardımıyla hesaplanan doygunluk (Saturation) bileşeni, vejetasyon indekslerinden FCI indeksine ait standart sapma değerleri, doku özelliklerinden WV-2’nin yeşil bandına ait entropi değerleri olduğu tespit edilmiştir.

**Çizelge 6.3 :** Obje tabanlı sınıflandırmada DVM-ÖÖE ile seçilen 50 özellik.

| Özellik ölçütü            |                | Seçilen Özellik         | Puan | Sıralama |
|---------------------------|----------------|-------------------------|------|----------|
| Temel spektral özellikler | Ortalama       | Kıyı                    | 2,67 | 17       |
|                           |                | Kızılötesi-1            | 3,14 | 11       |
|                           |                | Kızılötesi-2            | 3,84 | 2        |
|                           |                | Temel bileşen-1         | 0,63 | 43       |
|                           |                | NDVI-3                  | 3,76 | 3        |
|                           |                | NDVI-1                  | 1,96 | 26       |
|                           |                | NDSI                    | 2,04 | 25       |
|                           |                | NHFD                    | 0,31 | 47       |
|                           |                | PCABI                   | 1,10 | 37       |
|                           | Maksimum       | Mavi                    | 1,49 | 32       |
|                           |                | Kırmızı kenar           | 1,02 | 38       |
|                           |                | Temel bileşen-1         | 0,55 | 44       |
|                           |                | Temel bileşen-2         | 0,47 | 45       |
|                           |                | MSAVI                   | 2,43 | 20       |
|                           | Minimum        | Kıyı                    | 2,20 | 23       |
|                           |                | Yeşil                   | 3,29 | 9        |
|                           |                | Kızılötesi-1            | 0,39 | 46       |
|                           |                | Temel bileşen-1         | 1,33 | 34       |
|                           |                | Temel bileşen-2         | 1,73 | 29       |
|                           |                | Temel bileşen-3         | 1,57 | 31       |
|                           |                | NDSI                    | 0,78 | 41       |
|                           |                | NHFD                    | 1,88 | 27       |
|                           |                | ARVI                    | 0,94 | 39       |
|                           |                | OSAVI                   | 3,45 | 7        |
|                           |                | PCABI                   | 2,90 | 14       |
|                           | Standart sapma | NHFD                    | 3,22 | 10       |
|                           |                | FCI                     | 0,16 | 49       |
|                           | Maksimum fark  |                         | 2,59 | 18       |
|                           | Oran           | Yeşil                   | 2,75 | 16       |
|                           |                | Sarı                    | 3,37 | 8        |
|                           |                | Kırmızı                 | 3,61 | 5        |
|                           |                | Kırmızı kenar           | 1,25 | 35       |
|                           |                | Kızılötesi-1            | 3,69 | 4        |
|                           |                | Kızılötesi-2            | 1,80 | 28       |
|                           | HSI dönüşümü   | H (Kırmızı-Yeşil-Mavi)  | 3,92 | 1        |
|                           |                | H (NIR1- Kırmızı-Yeşil) | 2,98 | 13       |
|                           |                | H (NIR2- Kırmızı-Yeşil) | 3,06 | 12       |
|                           |                | S (Kırmızı-Yeşil-Mavi)  | 2,35 | 21       |
|                           |                | S (NIR1- Kırmızı-Yeşil) | 0,08 | 50       |
|                           |                | S (NIR2- Kırmızı-Yeşil) | 1,41 | 33       |
|                           |                | I (Kırmızı-Yeşil-Mavi)  | 1,65 | 30       |
|                           |                | I (NIR1- Kırmızı-Yeşil) | 3,53 | 6        |
|                           |                | I (NIR2- Kırmızı-Yeşil) | 2,27 | 22       |
| Doku Özellikleri          | Ortalama       | Kızılötesi-2            | 2,51 | 19       |
|                           | Korelasyon     | 45°                     | 0,71 | 42       |
|                           | Entropi        | Mavi                    | 0,86 | 40       |
|                           |                | Yeşil                   | 0,24 | 48       |
|                           |                | Kızılötesi-1            | 2,12 | 24       |
|                           | Homojenlik     | Mavi                    | 2,82 | 15       |
|                           |                | 0°                      | 1,18 | 36       |

Şekil 6.24’de DVM-ÖÖE ile seçilen en iyi 50 özellik, obje tabanlı sınıflandırmada esas alınan WV-2 görüntüsünün spektral bantları, vejetasyon indeksleri ve temel bileşenlerden oluşan 23 bandın kullanım sıklığı açısından ele alınmıştır. Şekil incelendiğinde, temel spektral özelliklerin ve doku özelliklerinin hesaplanmasında WV-2 görüntüsünün mavi, yeşil, kızılötesi-1 ve kızılötesi-2 bantlarının, diğer spektral bantlara oranla daha fazla kullanıldığı görülmektedir. Bu nedenle obje tabanlı sınıflandırmada benzer spektral özelliklere sahip arazi örtüsü/kullanım sınıflarının ayırt edilmesi noktasında WV-2’nin söz konusu bantlarının önemli olduğu ifade edilebilir. Yardımcı veri seti olarak kullanılan temel bileşenlerden, ilk bileşenin ortalama, maksimum ve minimum değerlerinin, ikinci bileşenin maksimum ve minimum değerlerinin ve üçüncü bileşenin ise minimum değerlerinin seçilen 50 özellik içerisinde yer aldığı tespit edilmiştir.



**Şekil 6.24 :** Obje tabanlı sınıflandırmada seçilen özelliklerin kullanılan bantlar açısından analizi.

Şekilden de görüleceği üzere WV-2'nin sarı, yeşil, kırmızı kenar ve kıyı bantlarını kullanarak hesaplanan NDSI ve NHFD indekslerine ait temel spektral özelliklerin diğer vejetasyon indekslerine göre daha önemli olduğu görülmektedir. Diğer vejetasyon indekslerinden NDVI-1 ve NDVI-3 indekslerine ait ortalama değerler, PCABI, OSAVI ve ARVI indekslerine ait minimum değerler, MSAVI indeksine ait maksimum değerler ve FCI indeksine ait standart sapma değerleri seçilen en iyi 50 özellik arasındadır. Değerlendirmeye alınan 12 vejetasyon indeksinden NDVI-2, EVI ve SAVI indekslerine ait hiçbir özellik ölçütünün 50 özellik içerisinde yer almadığı şekilden de görülmektedir.

Piksel tabanlı sınıflandırma işleminde değerlendirmeye alınan WV-2 görüntüsünün spektral bantları, vejetasyon indeksleri, temel bileşenler ve doku özelliklerinden 96 bantlı veri seti içerisinde, DVM-ÖÖE algoritması ile seçilen 50 özelliğe ait puanlamalar ve özelliklerin önem sıralamaları Çizelge 6.4'de gösterilmiştir. Seçilen özellikler çizelge de temel spektral özellikler ve doku özellikleri olarak iki genel özellik ölçütü altında incelenmiş ve analiz edilmiştir. Çizelge incelendiğinde seçilen özelliklerin 29 tanesinin temel spektral özellik, 21 tanesinin ise gri düzey eş oluşturma matrislerinden hesaplanan doku özellikleri olduğu görülmektedir. Bu durum görüntü piksellerinin temel spektral özellikleri ile birlikte görüntülerin doku özelliklerinin de sınıflandırma doğruluğu üzerinde etkili olduğunu gösteren bir ön bulgudur.

Seçilen özellikler analiz edildiğinde, WV-2'nin 8 spektral bandının DVM-ÖÖE ile belirlenen en iyi 50 özellik arasında olduğu görülmektedir. Bu bantlar arasında mavi ve kırmızı-1 bandı önem sırasına göre ilk beş bant içerisinde yer almaktadır. Temel bileşen analizi neticesinde elde edilen bileşenlerden tez kapsamında değerlendirmeye alınan ilk üç bileşenin de seçilen 50 özellik içerisinde yer aldığı, DVM-ÖÖE tarafından yapılan puanlamada ilk temel bileşenin (Temel bileşen-1) en yüksek puan aldığı görülmektedir. Yardımcı veri seti olarak değerlendirmeye alınan 12 vejetasyon indeksi içerisinde EVI ve ARVI indeksleri hariç diğer tüm vejetasyon indekslerinin en iyi 50 özellik içerisinde bulunduğu tespit edilmiştir. Çizelgeden de görüleceği üzere, vejetasyon indeksleri içerisinde kırmızı kenar ve kıyı bantlarını kullanarak hesaplanan NHFD indeksi en yüksek puanı almış olup seçilen 50 özellik içerisinde üçüncü sırada yer almaktadır. Bunun haricinde kırmızı-1, kırmızı-2 ve kırmızı kenar bantları kullanılarak hesaplanan NDVI-2 ve NDVI-3 vejetasyon indekslerinin ilk 10 özellik içerisinde olduğu görülmektedir.




**Çizelge 6.4 : Piksel tabanlı sınıflandırmada DVM-ÖÖE ile seçilen 50 özellik.**

|                           | Özellik ölçütü          | Özellik          | Puan                   | Sıralama |
|---------------------------|-------------------------|------------------|------------------------|----------|
| Temel Spektral Özellikler | WorldView-2             | Kıyı             | 2,98                   | 13       |
|                           |                         | Mavi             | 3,84                   | 2        |
|                           |                         | Yeşil            | 2,35                   | 21       |
|                           |                         | Sarı             | 1,02                   | 38       |
|                           |                         | Kırmızı          | 2,43                   | 20       |
|                           |                         | Kırmızı kenar    | 1,65                   | 30       |
|                           |                         | Kızılötesi-1     | 3,69                   | 4        |
|                           |                         | Kızılötesi-2     | 1,57                   | 31       |
|                           |                         | Temel bileşenler | Temel bileşen-1        | 2,82     |
|                           | Temel bileşen-2         |                  | 2,20                   | 23       |
|                           | Temel bileşen-3         |                  | 0,55                   | 44       |
|                           | Vejetasyon indeksleri   | NDVI-1           | 1,88                   | 27       |
|                           |                         | NDVI-2           | 3,45                   | 7        |
|                           |                         | NDVI-3           | 3,61                   | 5        |
|                           |                         | NDSI             | 3,06                   | 12       |
|                           |                         | NHFD             | 3,77                   | 3        |
|                           |                         | MSAVI            | 1,96                   | 26       |
|                           |                         | FCI              | 2,28                   | 22       |
|                           |                         | SAVI             | 1,80                   | 28       |
|                           |                         | OSAVI            | 1,49                   | 32       |
|                           |                         | PCABI            | 0,71                   | 42       |
|                           |                         | HSI dönüşümü     | H (Kırmızı-Yeşil-Mavi) | 3,14     |
|                           | H (NIR1- Kırmızı-Yeşil) |                  | 2,90                   | 14       |
|                           | H (NIR2- Kırmızı-Yeşil) |                  | 0,86                   | 40       |
|                           | S (Kırmızı-Yeşil-Mavi)  |                  | 3,92                   | 1        |
|                           | S (NIR1- Kırmızı-Yeşil) |                  | 2,59                   | 18       |
|                           | S (NIR2- Kırmızı-Yeşil) |                  | 2,67                   | 17       |
|                           | I (Kırmızı-Yeşil-Mavi)  |                  | 1,10                   | 37       |
|                           | I (NIR2- Kırmızı-Yeşil) |                  | 0,39                   | 46       |
| Doku Özellikleri          | Ortalama                | Kıyı             | 2,51                   | 19       |
|                           |                         | Mavi             | 2,12                   | 33       |
|                           |                         | Yeşil            | 1,41                   | 36       |
|                           |                         | Sarı             | 1,18                   | 10       |
|                           |                         | Kırmızı          | 3,22                   | 9        |
|                           |                         | Kırmızı kenar    | 3,29                   | 16       |
|                           |                         | Kızılötesi-1     | 2,75                   | 24       |
|                           |                         | Kızılötesi-2     | 2,04                   | 25       |
|                           |                         | Standart sapma   | Yeşil                  | 3,37     |
|                           | Kırmızı                 |                  | 1,26                   | 35       |
|                           | Kırmızı kenar           |                  | 1,73                   | 29       |
|                           | Kızılötesi-1            |                  | 0,31                   | 47       |
|                           | Kızılötesi-2            |                  | 0,78                   | 41       |
|                           | Homojenlik              | Sarı             | 0,24                   | 48       |
|                           | Zıtlık                  | Mavi             | 0,08                   | 50       |
|                           |                         | Kızılötesi-1     | 3,53                   | 6        |
|                           | Farklılık               | Kızılötesi-1     | 0,47                   | 45       |
|                           |                         | Kızılötesi-2     | 0,16                   | 49       |
|                           | Entropi                 | Kıyı             | 0,94                   | 39       |
|                           |                         | Kızılötesi-2     | 0,63                   | 43       |
|                           | Açısal ikinci moment    | Mavi             | 1,33                   | 34       |

Bununla birlikte kırmızı, yeşil, mavi, kızlötesi-1 ve kızlötesi-2 bantlarının farklı kombinasyonlarını kullanarak hesaplanan HSI bileşenlerinin tamamının da çizelgede yer aldığı görülmektedir. Bu bileşenler içerisinde, kırmızı, yeşil ve mavi bantlar yardımıyla hesaplanan doygunluk bileşeni en yüksek puan alarak ve özellik seçimine tabi tutulan 96 bantlı veri seti içerisinde en önemli özellik olduğu belirlenmiştir. Çizelgeden gri düzey eş oluşum matrisleri yardımıyla hesaplanan doku özellikleri içerisinde en fazla ortalama değerlerin yer aldığı görülmektedir. Nitekim WV-2'nin 8 multispektral bandına ait ortalama değerler en iyi 50 özellik içerisinde yer alırken, korelasyon ölçütü ile hesaplanan özellikler ilk 50 içerisinde yer almamaktadır.


Şekil 6.25'de DVM-ÖÖE ile seçilen en iyi 50 özellik, piksel tabanlı sınıflandırmada esas kullanılan bantların kullanım sıklığı açısından ele alınmıştır. Şekilden de görüleceği üzere, WV-2 görüntüsünün 8 spektral bandı arasında mavi, kızlötesi-1 ve kızlötesi-2 bantlarının diğer spektral bantlarına oranla daha fazla kullanıldığı görülmektedir. Özellikle WV-2'nin kızlötesi bantları seçilen özellikler içerisinde en fazla kullanılan bantlardır. Bunun temel nedeni DVM-ÖÖE ile seçilen en iyi 50 özellik içerisinde söz konusu bantların spektral yansıma değerlerinin yanında bantlara ilişkin hesaplanan doku özelliklerinin de yer almasıdır. Örneğin, kızlötesi-2 ve kızlötesi-2 bantlarının yansıma değerlerinin yanında, bu bantlardan yararlanarak hesaplanan ton, doygunluk ve yoğunluk bileşenleri ve bun bantlara ilişkin çeşitli doku özellikleri (ortalama, standart sapma, zıtlık, farklılık ve entropi) seçilen en iyi 50 özellik içerisinde yer almaktadır.

Şekil incelendiğinde yardımcı veri seti olarak kullanılan temel bileşenlerin tamamının en iyi 50 bant içerisinde yer aldığı görülmektedir. Bu bileşenlere ait doku özellikleri veya diğer görüntü dönüşümleri sonucunda elde edilen özelliklerden ziyade sadece bileşenlere ait piksel değerlerinin 50 özellik içerisinde yer aldığı belirlenmiştir. Şekilde, tezde değerlendirmeye alınan 12 vejetasyon indeksi içerisinde WV-2 görüntüsünün mavi, kırmızı ve kızlötesi-2 bantlarını kullanarak hesaplanan EVI ve ARVI indeksleri haricindeki diğer tüm vejetasyon indekslerinin söz konusu 50 özellik içerisinde yer aldığı görülmektedir.



**Şekil 6.25 :** Pikel tabanlı sınıflandırmada seçilen özelliklerin kullanılan bantlar açısından analizi.

Şekil 6.26’da obje ve piksel tabanlı sınıflandırmada DVM-ÖÖE algoritması ile seçilen en iyi 50 özellik kullanılan bantlar açısından bir arada değerlendirilmiştir. Şekilden de görüleceği üzere, WV-2 uydu görüntüsünün mavi, yeşil, kızılötesi-1 ve kızılötesi-2 bantlarının tezde ele alınan sınıflandırma probleminin çözümünde etkili olduğu tespit edilmiştir. Bununla birlikte temel bileşenlerin sahip oldukları bilgi içeriğine göre sonuca etki ettikleri belirlenmiştir. Örneğin WV-2’nin 8 spektral bandı arasındaki değişimlerin %71’ni temsil eden ilk temel bileşen obje ve piksel tabanlı sınıflandırmada en çok kullanılan temel bileşendir. Şekil incelendiğinde, WV-2’nin yeni spektral bantlarından kıyı, sarı ve kırmızı kenar bantlarını kullanarak hesaplanan NHFD ve NDSI indekslerinin diğer vejetasyon indekslerine göre daha sık kullanıldığı, EVI indeksinin ise hiç değerlendirmeye alınmadığı görülmektedir.



**Şekil 6.26 :** Obje ve piksel tabanlı sınıflandırmada kullanılan bantların analizi.

Tez kapsamında kullanılan özellik seçimi algoritmaları veri seti içerisindeki bantları ayrı ayrı değerlendirmiş ve sınıflandırma doğruluğuna etkilerini dikkate alarak en iyiden en kötüye doğru sıralamıştır. Algoritmalar özellik seçiminde farklı değerlendirme ölçütleri kullandığından aynı veri seti için her bir algoritma farklı bir sıralama belirlemiştir. Özellik seçimi algoritmalarının belirlediği bant sıralamaları bir arada analiz edildiğinde, veri seti içerisindeki bantların kullanılma sıklığı ve problem çözümünde hangi bantların daha önemli olduğu belirlenebilmektedir. Diğer bir ifadeyle, tüm sıralamalar bir arada değerlendirilerek veri seti içerisindeki her bir bandın ağırlığı tespit edilebilmektedir. Bu amaç doğrultusunda, 13 özellik seçimi algoritması tarafından belirlenen ilk 10 bant bir araya getirilerek 130 bandı içeren bir veri seti oluşturulmuştur. Gerek piksel gerekse obje tabanlı yaklaşımda elde edilen sonuçlar göz önüne alınarak ayrı ayrı oluşturulan veri setleri değerlendirilerek kullanım sıklığı en fazla olan 10 bant tespit edilmiştir. Çizelge 6.5’de obje ve piksel

tabanlı yaklaşımda 13 özellik seçimi algoritması tarafından belirlenen ilk 10 bandın bir arada değerlendirilmesi sonucunda tespit edilen en iyi 10 bant ve kullanım sıklıkları gösterilmiştir. Çizelge incelendiğinde obje tabanlı yaklaşımda WV-2 uydu görüntüsünün mavi, yeşil ve kırmızı bantlarının ortalama değerlerinin en iyi 10 bant arasında yer aldığı görülmektedir. Bununla birlikte görüntü objelerine ait parlaklık değerlerinin ve WV-2 uydu görüntüsünün kırmızı, yeşil, mavi ve yakın kızılötesi-1 bantları kullanılarak hesaplanan çeşitli görüntü dönüşüm bileşenlerinin de en iyi 10 bant içerisinde yer aldığı görülmektedir. Çizelge bantların kullanım sıklığı açısından analiz edildiğinde, tespit edilen en iyi 10 bandın, 130 bandı içeren veri seti içerisinde toplamda 43 defa kullanıldığı tespit edilmiştir. Diğer bir ifadeyle, tespit edilen en iyi 10 bant, 13 algoritmanın tahminleri birleşiminin %33'üne karşılık gelmektedir.

**Çizelge 6.5 :** Özellik seçimi algoritmaları tarafından tespit edilen en iyi 10 bant.

| Obje tabanlı yaklaşımda seçilen en iyi 10 bant | Kullanım Sıklığı | Piksel tabanlı yaklaşımda seçilen en iyi 10 bant | Kullanım sıklığı |
|------------------------------------------------|------------------|--------------------------------------------------|------------------|
| Parlaklık                                      | 6                | <b>PCA-1</b>                                     | 9                |
| <b>Ortalama-NDVI-2</b>                         | 6                | I(Kırmızı-Yeşil-Mavi)                            | 9                |
| <b>Ortalama-Mavi</b>                           | 5                | <b>NDVI-2</b>                                    | 8                |
| <b>Ortalama-Yeşil</b>                          | 5                | <b>Yeşil</b>                                     | 8                |
| <b>Ortalama-PCA-1</b>                          | 5                | Kırmızı kenar                                    | 7                |
| H(Kırmızı-Yeşil-Mavi)                          | 4                | H(NIR-1-Kırmızı-Yeşil)                           | 7                |
| S(NIR-2-Kırmızı-Yeşil)                         | 4                | <b>Ortalama Kırmızı</b>                          | 6                |
| <b>Ortalama-Kırmızı</b>                        | 4                | <b>Mavi</b>                                      | 6                |
| Oran-Kırmızı                                   | 4                | Ortalama NIR-2                                   | 6                |

Piksel tabanlı yaklaşım için elde edilen sonuçlar incelendiğinde, WV-2 görüntüsünün yeşil, kırmızı ve kırmızı kenar bantlarının en iyi 10 bant içerisinde olduğu görülmektedir. Bununla birlikte kırmızı ve yakın kızılötesi-2 bantlarının ise ortalama değerleri en iyi 10 bant arasında yer almaktadır. Diğer taraftan temel bileşenler analizi sonucunda elde edilen ilk temel bileşen ve WV-2'nin kırmızı, yeşil, mavi, kızılötesi-1 ve kızılötesi-2 bantları kullanılarak çeşitli görüntü dönüşümleri ile elde edilen bileşenler en iyi 10 bant içerisinde olduğu görülmektedir. Tespit edilen bantlar kullanım sıklığı açısından ele alındığında, 130 banttan oluşan veri seti içerisinde seçilen en iyi 10 bandın toplamda 66 kez yer aldığı görülmektedir. Bu sonuç, 13 algoritmanın seçimlerinin birleşimiyle oluşturulan veri setindeki bantların %50'sinin seçilen en iyi 10 banda karşılık geldiğini göstermektedir.

Piksel ve obje tabanlı yaklaşımda belirlenen en iyi 10 bant bir arada değerlendirildiğinde, çizelgede koyu olarak işaretlenen WV-2'nin kırmızı, mavi ve

yeşil bantlarının, ilk temel bileşenin ve WV-2'nin kırmızı ve kızılötesi-2 bantları yardımıyla hesaplanan vejetasyon indeksinin her iki yaklaşımda da ilk 10 bant içerisinde olduğu görülmüştür. Elde edilen bu sonuç, sınıflandırma probleminin çözümünde WV-2'nin mevcut spektral bantları kullanımı yerine çeşitli görüntü dönüşümleri ile elde edilen yardımcı verilerin daha etkili olduğunu destekler niteliktedir.

### **6.3.3 Tematik harita Üretimi ve Doğruluk Analizi**

Tez kapsamında 13 farklı arazi örtüsü/kullanım türünü temsil eden tematik harita üretiminde, değerlendirmeye alınan veri setleri, sınıflandırma yaklaşımları ve sınıflandırma algoritmaları arasında en yüksek sınıflandırma doğruluğunu üreten sınıflandırma modeli esas alınmıştır. Sınıflandırma yaklaşımı olarak, piksel tabanlı yaklaşıma göre %8'e varan doğruluk artışlarının gözlemlendiği obje tabanlı yaklaşım tercih edilmiştir. Obje tabanlı yaklaşımda kullanılan RotOR ve DVM algoritmaları ile diğer sınıflandırma algoritmalarından %5'e varan seviyelerde daha doğru sonuçlar elde edilmiştir. RotOR sınıflandırıcısı DVM-ÖÖE algoritması ile seçilen 50 özelliği içeren veri seti kullanarak %94,52 genel doğruluğa ulaşırken, DVM algoritması DVM-ÖÖE ile seçilen 40 özellik kombinasyonu ile %93,86 doğruluğa ulaşmıştır. Her iki sınıflandırma algoritması için test veri seti göz önüne alınarak hesaplanan genel doğruluklar birbirine çok yakın olduğundan tematik harita üretiminde ve doğruluk analizlerinde söz konusu algoritmalara ait sınıflandırma modelleri esas alınmıştır. Bu amaç doğrultusunda obje tabanlı yaklaşımda görüntü objeleri için belirlenen 216 özelliği içeren tüm veri seti DVM-ÖÖE ile belirlenen 40 ve 50 özelliği içerecek şekilde yeniden düzenlenerek sınıflandırma modellerine uygun veri setleri elde edilmiştir. RotOR ve DVM algoritmaları için belirlenen en uygun sınıflandırma modeller söz konusu veri setlerine uygulanarak tematik haritalar üretilmiştir.

RotOR algoritmasına için oluşturulan sınıflandırma modeli DVM-ÖÖE ile seçilen 50 özelliği içeren tüm veri setine uygulandığında Şekil 6.27'de gösterilen tematik harita üretilmiştir. Harita incelendiğinde tez kapsamında ele alınan ağaç türlerinin genel olarak doğru sınıflandırıldığı görülmektedir. Bununla birlikte, çalışma alanının kuzey-batı kesiminde geniş yapraklı zeytin ağacı sınıfındaki bazı piksellerin bölgedeki vejetasyon örtüsünü temsil eden bozkır sınıfına atanarak hatalı

sınıflandırıldığı görülmektedir. Bu durumun temel nedeni, sınıflandırmada modelinin oluşturulmasında zeytin ağaçlarını temsil eden objeleri içerisinde bozkır alanlarının da etkisinin bulunması ve bozkır alanları içerisindeki canlı vejetasyona ait spektral özelliklerin zeytin ağacına ait spektral özelliklere olan benzerliği olduğu düşünülmektedir.



**Şekil 6.27 :** RotOR algoritması ile üretilen tematik harita.

Tematik harita su geçirimsiz yüzeyler açısından ele alındığında, şekilden de görüleceği üzere, betonarme çatıya sahip binaları temsil eden bina-gri sınıfına ait bazı piksellerin benzer spektral özelliğe sahip yol sınıfına atandığı görülmektedir. Buna ilave olarak çalışma alanının güney-doğu kesiminde gerçekte toprak sınıfına ait olan piksellerden bir kısmının bina sınıfı içerisine dahil edilerek hatalı sınıflandırıldığı görülmektedir. Bu durumun kırmızı-bina olarak adlandırılan kiremit çatılı binalara ait spektral yansımaların toprak sınıfını oluşturan piksellerin yansımalarıyla olan benzerliğinden kaynaklandığı düşünülmektedir.








Harita üzerindeki su geçirimsiz yüzeyleri temsil eden sınıfların dağılımları incelendiğinde, en önemli sınıflandırma hatalarının genellikle bina-kırmızı olarak isimlendirilen ve kiremit çatı kaplamalarını temsil eden objelerin bir kısmının toprak sınıfı içerisinde dahil edilmesi ile ortaya çıktığı görülmektedir. Söz konusu hatalı sınıflandırmaların, çalışma bölgesinin güney-doğu kesimindeki toprak ve bozkır kaplı alanlarda ve çalışma alanının kuzeyinde yer alan geniş orman alanları içerisindeki toprak yollarda gerçekleştiği tematik haritadan kolaylıkla görülmektedir. RotOR algoritması ile üretilen tematik haritada da tespit edildiği gibi DVM ile üretilen tematik haritada da betonarme yapıları temsil eden bina-gri sınıfındaki bazı objelerin spektral olarak benzer özelliklere sahip yol sınıfına ait piksellerle karıştığı görülmektedir.

RotOR ve DVM algoritmaları ile üretilen tematik haritalar arasındaki farklılıkların görsel olarak analiz edilmesi amacıyla haritalar üzerinden belirli alt bölgeler belirlenmiş ve bu bölgeler içerisindeki değişimler analiz edilmiştir. Şekil 6.29'da tespit edilen 4 alt bölgenin orijinal WV-2 görüntüsü, RotOR ile üretilen tematik harita görüntüsü ve DVM ile üretilen tematik harita görüntüsü ayrı ayrı gösterilmiştir. Bununla birlikte gözlemlenebilen değişiklikler tematik haritalar üzerinde daire içerisine alınarak gösterilmiştir.

Şekil 6.29a'da kiremit çatı kaplamasına sahip bir binanın RotOR algoritmasıyla doğru olarak sınıflandırıldığı, buna karşın DVM ile sınıflandırılan haritada aynı bina çatısının bir kısmının toprak olarak sınıflandırıldığı görülmektedir. Aynı şekil üzerinde gerçekte sedir ağaçlarını içeren bir bölge RotOR ile doğru sınıflandırırken, DVM ile söz konusu ağaçların zeytin ve kızılçam olarak sınıflandırıldığı görülmektedir. Şekil 6.29b'de çalışma alanının zeytin ve fıstık çamı ağaçlarını içeren bir bölgesi değerlendirmeye alınmıştır. Şekilde fıstık çamı ağaçlarının zemininde ve etrafında bulunan bozkır örtüsünün RotOR algoritması ile doğru bir şekilde sınıflandırıldığı, buna karşın DVM algoritmasının bozkır alanlardan bir kısmını bina-kırmızı olarak sınıflandırdığı görülmektedir. Şeklin sağ alt kısmında daire içerisine alınan bölge içerisinde gerçekte geniş yapraklı çeşitli meyve ağaçlarına ait fidanlık bir alan mevcuttur. Bu alan RotOR algoritması geniş yapraklı fidan ağaçlarını geniş yapraklı zeytin ağacını temsil eden sınıfa atarken, DVM algoritması tarafından bu alanın büyük bir kısmı iğne yapraklı fıstık çamı olarak sınıflandırılmıştır.



**Şekil 6.29 :** Tematik haritaların karşılaştırılması

Şekil 6.29c’de çalışma alanındaki genç fıstık çamlarını içeren alt bölgeye ait haritalar incelendiğinde, fıstık çamlarının zeminindeki bozkır ve toprak örtüsünün RotOR algoritması daha yüksek doğrulukta sınıflandırıldığı, DVM algoritmasının bu sınıflara ait objelerin bir kısmını bina-kırmızı sınıfı içerisine dahil ederek hatalı sınıflandırdığı görülmektedir. Şekilde gösterilen fıstık ağaçlarının sınıflandırılmasında RotOR algoritmasının DVM’ye göre daha başarılı olduğu belirlenmiştir. Bunun temel nedeni DVM ile üretilen tematik haritada fıstık

çamlarının gölgeli kısımlarındaki görüntü objelerinin zeytin ağacı sınıfına atanarak hatalı sınıflandırılmasıdır. Bunun temel nedeninin diğer ağaç türlerine göre çok küçük bir kanopiye sahip zeytin ağaçlarının segmentasyonu sırasında bazı zeytin ağaçlarının gölgeli kısımlarının zeytin objesi olarak belirlenmesi ve sınıflandırma modelinin oluşturulmasında bu objelerinde değerlendirmeye alınması olduğu düşünülmektedir. Şekil 6.29d’de çalışma bölgesindeki en yoğun bozkır ve toprak alanlarını içeren alt bölge ele alınmıştır. Bu bölge içerisinde algoritmaları tarafından gerçekleştirilen sınıflandırmalar ele alındığında, RotOR algoritmasının aynı bölgede daha fazla toprak alan sınıflandırması yaptığı açıkça görülmektedir. Alt bölgedeki vejetasyonun canlılığının diğer bölgelere göre daha az olması, bölgenin çok küçük ve seyrek otları içeren bozkır örtüsüne sahip olmasının bu durumun ortaya çıkmasının temel nedeni olduğu düşünülmektedir. Bununla birlikte DVM algoritmasının toprak sınıfına ait bazı objeleri ve bina-kırmızı sınıfı içerisine dahil ettiği görülmektedir. Diğer taraftan her iki algoritmanın betonarme kaplamaya sahip bina çatılarına ait bazı objeleri yol sınıfına atayarak hatalı sınıflandırdığı görülmektedir.

RotOR ve DVM algoritmaları tarafından üretilen tematik haritaların görsel olarak yorumlanmasının yanında algoritmaların sınıflandırma performanslarının karşılaştırılması, sınıflandırma doğrulukları ile ilgili detaylı istatistiksel analizlerinin gerçekleştirilmesi ve haritaların yer gerçekliğinin araştırılması amacıyla doğrulama veri seti oluşturulmuştur. Doğrulama veri seti, algoritmaların eğitim ve test edilmesinde kullanılan veri setlerinden bağımsız olarak örnekleme alanları dışarısında kalan alanlar içerisinde belirlenmiştir. Karşılaştırma ve analizlerin objektifliğini sağlamak amacıyla tespit edilen doğrulama alanları içerisinde rastgele örnekleme prensibinden hareketle her bir arazi örtüsü/kullanım sınıfı için eşit sayıda piksel (350 piksel) içerecek şekilde toplam 4.550 pikselden oluşan doğrulama veri seti üretilmiştir. Sınıflandırma algoritmalarının performanslarının araştırılmasında hata matrisleri yardımıyla hesaplanan genel doğruluk, kappa değeri gibi temel doğruluk ölçütlerinin yanında üretilen arazi örtüsü/kullanım sınıflarının her birinin sınıflandırma doğruluğu hakkında bilgi sağlayan kullanıcı ve üretici doğrulukları da hesaplanarak detaylı şekilde analiz edilmiştir.

Doğrulama veri seti ve RotOR algoritması tarafından üretilen tematik haritanın ilişkilendirilmesi sonucunda hesaplanan hata matrisi Çizelge 6.6’da gösterilmiştir. RotOR algoritması ile test veri seti için hesaplanan en yüksek doğruluk %94,52

olarak hesaplanmasına rağmen, doğrulama veri seti için hesaplanan genel doğruluğun %91,03 olduğu görülmektedir. Hata matrisi incelendiğinde su geçirimsiz yüzey olarak adlandırılan arazi kullanım sınıfları içerisinde kiremit çatıya sahip binaları temsil eden bina-kırmızı ve beyaz çatıya sahip binaları gösteren bina-beyaz sınıflarına ait piksellerin tamamının veya tamamına yakınının doğru sınıflandırıldığı görülmektedir. Bunun yanında özellikle beton çatıya sahip binaları temsil eden bina-gri sınıfındaki piksellerin yaklaşık üçte birlik bir kısmının benzer spektral özelliklere sahip yol sınıfına atanarak hatalı sınıflandırıldığı görülmektedir. Aynı şekilde yol sınıfına ait piksellerin bir kısmının da bina-gri sınıfına atandığı görülmektedir.

**Çizelge 6.6 :** RotOR algoritması için hesaplanan hata matrisi.

|    | BK         | BB         | BG         | Y          | T          | S          | B          | Ç          | FÇ         | KÇ         | SD         | Z          | G          |
|----|------------|------------|------------|------------|------------|------------|------------|------------|------------|------------|------------|------------|------------|
| BK | <b>349</b> | 0          | 0          | 0          | 0          | 0          | 1          | 0          | 0          | 0          | 0          | 0          | 0          |
| BB | 0          | <b>350</b> | 0          | 0          | 0          | 0          | 0          | 0          | 0          | 0          | 0          | 0          | 0          |
| BG | 0          | 0          | <b>246</b> | 102        | 2          | 0          | 0          | 0          | 0          | 0          | 0          | 0          | 0          |
| Y  | 0          | 0          | 28         | <b>314</b> | 4          | 4          | 0          | 0          | 0          | 0          | 0          | 0          | 0          |
| T  | 0          | 0          | 0          | 0          | <b>350</b> | 0          | 0          | 0          | 0          | 0          | 0          | 0          | 0          |
| S  | 0          | 0          | 0          | 29         | 0          | <b>312</b> | 0          | 0          | 0          | 0          | 0          | 0          | 9          |
| B  | 0          | 0          | 0          | 0          | 0          | 0          | <b>346</b> | 4          | 0          | 0          | 0          | 0          | 0          |
| Ç  | 0          | 0          | 0          | 0          | 0          | 0          | 2          | <b>347</b> | 0          | 0          | 1          | 0          | 0          |
| FÇ | 0          | 0          | 0          | 0          | 0          | 0          | 0          | 0          | <b>320</b> | 0          | 4          | 26         | 0          |
| KÇ | 0          | 0          | 0          | 0          | 0          | 0          | 0          | 0          | 50         | <b>293</b> | 7          | 0          | 0          |
| SD | 0          | 0          | 0          | 0          | 0          | 0          | 2          | 0          | 1          | 25         | <b>283</b> | 0          | 39         |
| Z  | 0          | 0          | 0          | 0          | 0          | 0          | 22         | 0          | 13         | 0          | 0          | <b>314</b> | 1          |
| G  | 0          | 0          | 0          | 4          | 0          | 27         | 0          | 0          | 0          | 1          | 0          | 0          | <b>318</b> |

Genel doğruluk: %91,03 Kappa: 0.903

\*BK, bina-kırmızı; BB, bina-beyaz; BG, bina-gri; Y, yol; T, toprak; S, su; B, bozkır; Ç, çınar; FÇ, fıstık çamı; KÇ, kızılçam; SD, sedir; Z, zeytin; G, gölge.

RotOR algoritmasının ağaç türlerinin sınıflandırılmasındaki performansı analiz edildiğinde, pikseller arasında en az karışıklığın geniş yapraklı çınar ağacını temsil eden sınıfta olduğu görülmektedir. Geniş yapraklı zeytin ağacına ait piksellerin bir kısmının (35 piksel) bozkır ve fıstık çamı sınıfına atanarak hatalı sınıflandırıldığı tespit edilmiştir. İğne yapraklı ağaç türleri arasında en doğru sınıflandırmanın fıstık çamı pikselleri için gerçekleştiği görülmektedir. Diğer iğne yapraklı ağaç türlerinden kızılçam pikselleri en çok fıstık çamı pikselleriyle karışırken, sedir ağacını temsil eden piksellerin kızılçam ve gölge sınıfına ait piksellerle karıştığı görülmektedir. Sedir ağaçlarına ait piksellerin bir kısmının (39 piksel) gölge sınıfına atanarak hatalı sınıflandırılmasının temel nedeni, sedir ağacının doğal yapısının bir sonucu olarak kendi dalların ortaya çıkardığı gölge etkisi olduğu düşünülmektedir. Çizelgede temel

arazi örtüsü olarak kabul edilen toprak ve bozkır sınıflarına ait piksellerin tamamının veya tamamına yakınının doğru sınıflandırıldığı görülmektedir. Yüksek çözünürlüklü görüntülerde önemli bir problem olan gölge sınıfına ait piksellerin en çok su sınıfına ait pikseller ile karıştığı söylenebilir. Gölge sınıfındaki hatalı sınıflandırmaların temel nedeninin gölge ve su pikselleri arasındaki spektral benzerlik ve çalışma alanındaki dere üzerinden seçilen örnek su objelerinden kaynaklandığı düşünülmektedir.

DVM ile üretilen tematik harita doğrulama veri seti ile ilişkilendirilerek doğruluk analizlerinde kullanılacak hata matrisi hesaplanmıştır. Çizelge 6.7’de hata matrisi kullanılarak DVM ile üretilen tematik harita doğruluğunun %89,56 olarak hesaplandığı görülmektedir. DVM algoritmasının su geçirimsiz yüzeylerin sınıflandırılmasındaki performansı incelendiğinde, bina-gri ve yol sınıflarına ait piksellerin ayırt edilmesinde düşük performans sergilediği görülmektedir. Nitekim bina-gri sınıfına ait piksellerin üçte birinin yol sınıfına atandığı, aynı şekilde yol sınıfına ait piksellerin önemli bir kısmının bina-gri sınıfına atandığı tespit edilmiştir.

Değerlendirmeye alınan geniş ve iğne yapraklı ağaç türleri içerisinde çınar ağacını temsil eden piksellerin diğerlerine oranla daha doğru sınıflandırıldığı, hatalı sınıflandırılan piksellerin tamamının canlı vejetasyonu temsil eden bozkır sınıfına atandığı tespit edilmiştir. İğne yapraklı ağaç türlerine ait sınıflandırmalar incelendiğinde en az hatalı sınıflandırılan piksel sayısı fıstık çamı sınıfında görülürken, en fazla karışıklığın sedir sınıfındaki piksellerin ayırt edilmesinde ortaya çıktığı görülmektedir. Kızılçam pikselleri en fazla fıstık çamı pikselleri ile karıştırılırken, sedir sınıfı pikselleri fıstık çamı ve kızılçam pikselleri ile karıştığı söylenebilir. Sedir ağacına ait piksellerin bir kısmının yine gölge sınıfı içerisine dahil edilerek hatalı sınıflandırıldığı tespit edilmiştir. Ağaç türlerini temsil eden sınıflar içerisinde hatalı sınıflandırmaların en fazla zeytin sınıfında gerçekleştiği ve zeytin piksellerinin bozkır, fıstık çamı ve kızılçam sınıfına atanarak hatalı sınıflandırıldığı görülmektedir. Tez kapsamında temel arazi örtüsü olarak kabul edilen toprak ve bozkır sınıflarındaki piksellerin tamamına yakınının doğru sınıflandırıldığı, su sınıfına ait piksellerin bir kısmının benzer spektral özelliklere sahip gölge sınıfına dahil edildiği tespit edilmiştir.

**Çizelge 6.7 : DVM algoritması için hesaplanan hata matrisi.**

|    | BK         | BB         | BG         | Y          | T          | S          | B          | Ç          | FÇ         | KÇ         | SD         | Z          | G          |
|----|------------|------------|------------|------------|------------|------------|------------|------------|------------|------------|------------|------------|------------|
| BK | <b>329</b> | 0          | 0          | 0          | 20         | 0          | 1          | 0          | 0          | 0          | 0          | 0          | 0          |
| BB | 0          | <b>346</b> | 0          | 0          | 4          | 0          | 0          | 0          | 0          | 0          | 0          | 0          | 0          |
| BG | 0          | 2          | <b>255</b> | 90         | 2          | 0          | 1          | 0          | 0          | 0          | 0          | 0          | 0          |
| Y  | 0          | 0          | 32         | <b>314</b> | 0          | 4          | 0          | 0          | 0          | 0          | 0          | 0          | 0          |
| T  | 10         | 0          | 0          | 0          | <b>336</b> | 0          | 4          | 0          | 0          | 0          | 0          | 0          | 0          |
| S  | 0          | 0          | 0          | 1          | 6          | <b>305</b> | 0          | 0          | 0          | 0          | 1          | 0          | 37         |
| B  | 0          | 0          | 0          | 0          | 0          | 0          | <b>341</b> | 8          | 0          | 0          | 0          | 1          | 0          |
| Ç  | 0          | 0          | 0          | 0          | 0          | 0          | 15         | <b>335</b> | 0          | 0          | 0          | 0          | 0          |
| FÇ | 0          | 0          | 0          | 0          | 0          | 0          | 0          | 0          | <b>311</b> | 6          | 4          | 29         | 0          |
| KÇ | 0          | 0          | 0          | 0          | 0          | 0          | 0          | 0          | 43         | <b>302</b> | 5          | 0          | 0          |
| SD | 0          | 0          | 0          | 0          | 0          | 0          | 7          | 0          | 10         | 36         | <b>270</b> | 2          | 25         |
| Z  | 0          | 0          | 0          | 0          | 0          | 0          | 20         | 0          | 25         | 9          | 0          | <b>296</b> | 0          |
| G  | 0          | 0          | 0          | 4          | 0          | 6          | 0          | 0          | 0          | 1          | 4          | 0          | <b>335</b> |

Genel doğruluk: %89,56 Kappa: 0.887

\*BK, bina-kırmızı; BB, bina-beyaz; BG, bina-gri; Y, yol; T, toprak; S, su; B, bozkır; Ç, çınar; FÇ, fıstık çamı; KÇ, kızılçam; SD, sedir; Z, zeytin; G, gölge.

Hata matrisi yardımıyla hesaplanan genel doğruluk değerlendirmeye alınan örnek piksellerin yüzde kaçının doğru sınıflandırıldığı ile ilgili bir doğruluk ölçütü olup, değerlendirmeye alınan sınıfların doğruluğu hakkında herhangi bir bilgi vermemektedir. Hata matrisi yardımıyla hesaplanan kullanıcı ve üretici doğrulukları sınıf doğrulukları hakkında bilgi edinilmesinde kullanılan önemli doğruluk ölçütlerindendir. Üretici doğruluğu yeryüzü üzerindeki belirli bir arazi örtüsünün ne kadar doğrulukta sınıflandırıldığını gösterirken, kullanıcı doğruluğu belirli bir arazi örtüsüne atanan bir pikselin gerçekte de o sınıfta olma doğruluğunu gösteren bir ölçüttür. Örneğin, RotOR algoritmasıyla yol sınıfına için kullanıcı doğruluğu %89,71, üretici doğruluğu ise %69,93 olarak hesaplanmıştır. Elde edilen bu sonuçlar, yol olarak sınıflandırılan tüm piksellerin %89,71'inin yeryüzünde gerçekten yol alanlarına karşılık geldiğini, buna karşın tüm yol piksellerinin yalnızca %69,93'ünün yol olarak sınıflandırıldığını göstermektedir.

Çizelge 6.8'de RotOR ve DVM algoritmaları ile sınıflandırılan 13 arazi örtüsü/kullanım sınıfına ait hesaplanan kullanıcı ve üretici doğrulukları verilmiştir. Çizelge hesaplanan üretici doğrulukları açısından ele alındığında, bina-gri, kızılçam, gölge ve yol haricindeki tüm sınıflar için RotOR algoritmasının DVM algoritmasına göre daha yüksek doğrulukta sonuçlar elde ettiği görülmektedir. Diğer bir ifadeyle söz konusu dört sınıf haricindeki diğer sınıflara ait piksellerin, yeryüzünde gerçekten ait oldukları sınıfa atanmalarında RotOR algoritması daha üstün performans sergilediği ifade edilebilir. Her iki algoritma da bina-gri sınıfını oluşturan piksellerin

sınıflandırılmasında %70 seviyelerinde kullanıcı doğruluğu üretmişlerdir. RotOR algoritması bina-beyaz ve toprak sınıflarına ait tüm pikselleri doğru olarak sınıflandırırken, DVM bina-beyaz sınıfı için %2, toprak sınıfı için %4 daha düşük sınıflandırma doğruluğuna ulaşmıştır.

Ağaç türlerine ilişkin kullanıcı doğrulukları analiz edildiğinde, kızılçam haricindeki tüm ağaç türlerinin RotOR algoritması ile %4'e varan düzeylerde daha doğru sınıflandırıldığı görülmektedir. Kızılçam sınıfı DVM algoritması ile %86,29 kullanıcı doğruluğu ile sınıflandırılırken, RotOR algoritması ile hesaplanan doğruluk %83,71'dir. Diğer taraftan gölge alanlarının DVM algoritması ile %5 daha doğru sınıflandırıldığı görülmektedir. Sınıflandırma algoritmalarının performansı hesaplanan üretici doğrulukları açısından ele alındığında, RotOR algoritmasıyla su ve yol sınıfları haricindeki tüm sınıflar için daha yüksek üretici doğruluğuna ulaştığı belirlenmiştir (Çizelge 6.8).

RotOR algoritması bina-kırmızı ve bina-beyaz sınıflarına ait piksellerin tamamını doğru olarak sınıflandırırken, DVM kiremit çatı kaplamasına sahip binaları temsil eden piksellerin ayırt edilmesinde daha düşük performans sergilemiştir. Kullanıcı doğrulukları ile karşılaştırıldığında bina-gri, kızılçam ve gölge sınıflarının DVM'ne göre daha yüksek doğrulukta sınıflandırıldığı görülmektedir. Üretici doğrulukları, ağaç türlerini temsil eden sınıflar açısından değerlendirildiğinde, tüm ağaç türlerin RotOR algoritması yardımıyla daha doğru bir şekilde ayırt edilebildiği ifade edilebilir.

**Çizelge 6.8 :** Hata matrisleri yardımıyla hesaplanan kullanıcı ve üretici doğrulukları.

| Sınıf        | Kullanıcı doğruluğu (%) |       | Üretici doğruluğu (%) |       |
|--------------|-------------------------|-------|-----------------------|-------|
|              | RotOR                   | DVM   | RotOR                 | DVM   |
| Bina-kırmızı | 99,71                   | 94,00 | 100                   | 97,05 |
| Bina-beyaz   | 100                     | 98,86 | 100                   | 99,43 |
| Bina-gri     | 70,29                   | 72,86 | 89,78                 | 88,85 |
| Yol          | 89,71                   | 89,71 | 69,93                 | 76,77 |
| Toprak       | 100                     | 96,00 | 98,32                 | 91,30 |
| Su           | 89,14                   | 87,14 | 90,96                 | 96,83 |
| Bozkır       | 98,86                   | 97,43 | 92,76                 | 87,66 |
| Çınar        | 99,14                   | 95,71 | 98,86                 | 97,67 |
| Fıstık çamı  | 91,43                   | 88,86 | 83,33                 | 79,95 |
| Kızılçam     | 83,71                   | 86,29 | 91,85                 | 85,31 |
| Sedir        | 80,86                   | 77,14 | 95,93                 | 95,07 |
| Zeytin       | 89,71                   | 84,57 | 92,35                 | 90,24 |
| Gölge        | 90,86                   | 95,71 | 86,65                 | 84,38 |

Hata matrisi yardımıyla hesaplanan genel doğruluk, kullanıcı ve üretici doğrulukları yardımıyla sınıflandırma algoritmalarının performanslarının karşılaştırılmasının yanında, RotOR ve DVM için hesaplanan genel sınıflandırma doğrulukları arasındaki farkın istatistiksel anlamlılığı McNemar's testi kullanılarak analiz edilmiştir. Ki-kare dağılımını esas alan McNemar's testi temel olarak iki sınıflandırıcının sınıflandırma hatalarının karşılaştırılması esasına dayanmaktadır. McNemar's testi hesaplamalarda  $2 \times 2$  boyutlu bir hata matrisi kullanılmaktadır (Foody, 2004; Japkowicz ve Shah, 2011).

$A_1$  ve  $A_2$  olarak adlandırılan iki sınıflandırma algoritmasının test veri seti ( $S_{test}$ ) için elde ettiği sınıflandırma sonuçlarının  $f_1$  ve  $f_2$  olduğu düşünölsün. Bu durumda McNemar's testi hesaplamalarında kullanılacak  $2 \times 2$  boyutlu hata matrisi ( $C_{MC}$ ) Çizelge 6.9'da gösterildiği şekilde oluşturulur. Matriste  $c_{00}^{Mc}$ ,  $A_1$  ve  $A_2$  algoritmanın her ikisinin de hatalı sınıflandırdığı piksel sayısını;  $c_{01}^{Mc}$ ,  $A_1$  algoritması tarafından yanlış  $A_2$  algoritması tarafından doğru sınıflandırılan piksel sayısını;  $c_{10}^{Mc}$ ,  $A_1$  algoritması tarafından doğru  $A_2$  algoritması tarafından yanlış sınıflandıran piksel sayısını ve  $c_{11}^{Mc}$ ,  $A_1$  ve  $A_2$  algoritmanın her ikisinin de doğru sınıflandırdığı piksel sayısını göstermektedir.

**Çizelge 6.9 :**  $A_1$  ve  $A_2$  sınıflandırıcıları için hesaplanan McNemar's hata matrisi.

|                                                             |   | A <sub>2</sub> algoritmasının sınıflandırma sonucu |               |
|-------------------------------------------------------------|---|----------------------------------------------------|---------------|
|                                                             |   | $f_2$                                              |               |
|                                                             |   | 0                                                  | 1             |
| A <sub>1</sub> algoritmasının sınıflandırma sonucu<br>$f_1$ | 0 | $c_{00}^{Mc}$                                      | $c_{01}^{Mc}$ |
|                                                             | 1 | $c_{10}^{Mc}$                                      | $c_{11}^{Mc}$ |

Sıfır hipotezi  $A_1$  ve  $A_2$  algoritmalarının aynı performansa ve dolayısıyla aynı hata oranına sahip olduğu kabulünü yapmaktadır. Bu nedenle  $c_{01}^{Mc} = c_{10}^{Mc} = c_{null}^{Mc}$  olduğu kabul edilir. Bir sonraki adımda matris elemanları kullanılarak (6.1) yardımıyla ki-kare ( $\chi^2$ ) dağılımındaki McNemar's test istatistiği hesaplanır. Hesaplanan istatistik değeri ki-kare dağılımını gösteren tablo değerinden belirlenen güven aralığında büyük olduğunda sıfır hipotezi reddedilir. Örneğin hesaplanan istatistik değeri ( $\chi_{Mc}^2$ ), %95



güven aralığında  $\chi^2 = 3,841$  tablo değerinden büyük olduğunda sıfır hipotezi reddedilerek  $A_1$  ve  $A_2$  algoritmalarının sınıflandırma performansları ve hata oranları arasındaki farkın istatistiksel olarak anlamlı olduğu sonucuna ulaşılır. Diğer ifadeyle bu sonuç iki sınıflandırma sonucunun birbirinden farklı olduğunun istatistiksel bir göstergesidir.

$$\chi_{Mc}^2 = \frac{(|c_{01}^{Mc} - c_{10}^{Mc}| - 1)^2}{c_{01}^{Mc} + c_{10}^{Mc}} \quad (6.1)$$

Doğrulama veri seti için RotOR ve DVM algoritmalarının sergilediği sınıflandırma performansları arasındaki farklılık McNemar's testi kullanılarak analiz edilmiştir. 13 arazi örtüsü ve kullanım sınıf için toplam 4.550 pikselden oluşan doğrulama veri setindeki bilinen sınıf etiketleri RotOR ve DVM ile tahmin edilen sınıf etiketleri ile birlikte analiz edilerek Çizelge 6.10'da gösterilen  $2 \times 2$  boyutlu hata matrisi hesaplanmıştır. Çizelge incelendiğinde her iki sınıflandırma algoritması tarafından doğru sınıflandırılan piksel sayısının 3.921, her iki algoritma tarafından yanlış sınıflandırılan piksel sayısının 254 olduğu görülmektedir. RotOR algoritmasının yanlış DVM algoritmasının doğru sınıflandırdığı piksel sayısı 154, RotOR algoritması tarafından doğru DVM tarafından yanlış sınıflandırılan piksel sayısının ise 221 olduğu görülmektedir. Oluşturulan hata matrisi elemanları kullanılarak (6.1)'de verilen formül yardımıyla hesaplanan McNemar's istatistik değeri  $\chi_{RotOR\_DVM}^2 = 11,616$  'dır. Hesaplanan değer %95 güven aralığında  $\chi^2 = 3,841$  tablo değerinden büyük olduğundan doğrulama veri seti için RotOR ve DVM algoritmalarının farklı sınıflandırma performansları gösterdiği sonucuna ulaşılmaktadır. Diğer bir ifadeyle doğrulama verisi için RotOR ve DVM algoritmalarıyla hesaplanan genel doğruluklar arasındaki %1,47'lik fark istatistiksel olarak anlamlı bir fark olup, bu veri seti için RotOR algoritmasının DVM algoritmasından istatistiksel olarak daha iyi bir sınıflandırma performansı sergilediğini göstermektedir.

**Çizelge 6.10 :** RotOR ve DVM algoritmaları için hesaplanan hata matrisi.

|              |          | <i>DVM</i> |          |
|--------------|----------|------------|----------|
|              |          | <b>0</b>   | <b>1</b> |
| <i>RotOR</i> | <b>0</b> | 254        | 154      |
|              | <b>1</b> | 221        | 3.921    |



## 7. SONUÇ VE ÖNERİLER

Son yıllarda uydu görüntüleme sistemleri ve algılayıcılarında yaşanan yenilikler neticesinde yeryüzündeki doğal ve yapay nesnelere ilişkin gerek konumsal gerekse spektral anlamda çok daha detaylı bilgiler elde edilebilmektedir. Uydu görüntülerinin sağladığı bilgi içeriğindeki bu değişim global ve yerel ölçekte yeryüzü nesnelerinin varlığı, konumsal dağılımları ve çeşitliliğinin tespiti noktasında yeni araştırma olanakları ortaya çıkarmıştır. Yeni nesil uydu görüntüleri kullanıcılara detaylı bilgiler sağlamasına karşın, görüntüler üzerinden bilgi çıkarımı noktasında karmaşık yapıda ve benzer karakteristiklere sahip piksellerin bir arada değerlendirilmesi ve analizi söz konusudur. Uzaktan algılanmış görüntüler üzerinden söz konusu bilgilerin elde edilmesinde başlıca kullanılan yöntem sınıflandırmadır. Sınıflandırma işleminin gerçekleştirilmesinde birçok istatistiksel sınıflandırma tekniğinin geliştirilmesi ve kullanılmasına karşın, özellikle benzer spektral özelliklere sahip ve karmaşık yapıda yoğun görüntü piksellerini içeren yüksek çözünürlüklü uydu görüntülerinin sınıflandırılması ve analizinde gelişmiş yöntem ve yaklaşımlara ihtiyaç duyulmaktadır.

Tez kapsamında yüksek çözünürlüklü uydu görüntüleri üzerinden spektral olarak benzer özelliklere sahip doğal nesneler olarak nitelendirilen ağaç türlerinin ayırt edilmesi, sınıflandırılması ve haritalanması probleminin çözümüne yönelik bir yaklaşımın ortaya konulması amaçlanmıştır. Bu amaç doğrultusunda yüksek çözünürlüklü uydu görüntüsünün sınıflandırılması ve tematik harita üretimi aşamaları ayrıntılı olarak ele alınmış ve problem çözümüne optimum katkı sağlayacak bütünlüklü bir sınıflandırma modeli ortaya koyulmuştur.

Tezin genel amacı doğrultusunda sınıflandırmaya esas uydu görüntüsü olarak 8 spektral banda ve 2m konumsal çözünürlüğe sahip tek uydu görüntüsü olan WorldView-2 görüntüsü değerlendirmeye alınmıştır. Arazi çalışmaları neticesinde tespit edilen ağaç türlerinin ASD FieldSpec3 spektrometre cihazı ile spektral özellikleri ölçülerek, ağaç türlerine özgü spektral kütüphane oluşturulmuştur. Tez kapsamında değerlendirmeye alınan ağaç türlerinin yanında, su geçirimsiz yüzeyler

olarak tanımlanan ve benzer spektral özellik gösteren binalar ve yol sınıflarına ilave olarak temel arazi örtüsü sınıfları (toprak, su ve bozkır) da oluşturulmuştur. Sınıflandırma doğruluğunun ve tez kapsamında ele alınan arazi örtüsü/kullanımı sınıfları arasındaki spektral ayrımın arttırılması amacıyla çeşitli görüntü dönüşüm yöntemleri (vejetasyon indeksleri, temel bileşenler analizi, ton-doygunluk-yoğunluk dönüşümleri ve doku özellikleri) uygulamada değerlendirilmeye alınmıştır. Uydu görüntüsü ve yardımcı verilerden oluşan yüksek boyutlu veri seti içerisindeki faydasız, birbiri ile korelasyonlu ve gereksiz bilgileri içeren özelliklerin (bantların) elenmesi amacıyla birçoğu uzaktan algılama alanında yeni kullanıma sahip 13 farklı özellik seçimi algoritması kullanılmıştır. Seçilen özellikleri içeren veri setlerinin sınıflandırılması ve tematik harita üretiminde hem geleneksel piksel tabanlı yaklaşım hem de obje tabanlı yaklaşım değerlendirmeye alınmıştır. Piksel ve obje tabanlı sınıflandırma işleminin gerçekleştirilmesinde geleneksel en yakın komşuluk algoritmasının yanında 7 farklı makine öğrenme algoritması değerlendirmeye alınmıştır. Tezde önerilen amaç doğrultusunda gerçekleştirilen çalışmalar sonucunda elde edilen bulgular aşağıda maddeler halinde sıralanmıştır:

- Çalışma sonuçları WV-2 uydu görüntüsünün mevcut spektral bantlarının değerlendirmeye alınan 13 arazi örtüsü/kullanım sınıfının birbirinden ayırt edilmesinde etkili ama yetersiz olduğunu göstermektedir. Özellikle WV-2 görüntüsünün kırmızı kenar, kızılötesi-1 ve kızılötesi-2 bantlarının ağaç türlerinin birbirinden ayırt edilmesi noktasında kritik öneme sahip olduğu belirlenmiştir.
- Tez kapsamında değerlendirmeye alınan 9 farklı ağaç türünün spektral özellikleri ölçülerek ağaç türlerine özgü spektral kütüphane oluşturulmuştur. Spektral özelliklerin analizi neticesinde spektrumun hangi bölgesinde bitki türlerinin ayırt edilebilir olduğu belirlenebilmektedir. Bu özelliği sayesinde oluşturulan spektral kütüphane uydu görüntüsünün seçiminde önemli bir kaynak durumunda olup, bölgede gerçekleştirilecek sonraki çalışmalar için önemli bir envanter niteliğindedir.
- Spektral kütüphane kontrollü sınıflandırma işleminin gerçekleştirilmesinde ön koşul olan ve sınıflandırma başarısını direkt olarak etkileyebilen yeter sayıda, dağılımda ve doğrulukta örnekleme alanlarının tespitinde büyük rol oynamaktadır.

- WV-2 görüntüsü ve çeşitli görüntü dönüşümleri ile üretilen yardımcı verilerden oluşan yüksek boyutlu veri setinin tamamı sınıflandırma işlemine tabi tutulduğunda, sınıflandırma doğruluğunda piksel tabanlı yaklaşımda %1 obje tabanlı yaklaşımda %2 seviyelerinde artış olduğu tespit edilmiştir.
- Çalışma sonuçları, değerlendirmeye alınan yüksek boyutlu veri setinin tamamının sınıflandırma işleminde kullanılması yerine, uygun bir özellik seçimi yaklaşımıyla veri seti boyutunun %60-70 düzeyinde azaltılabileceğini ve seçilen özellikler ile sınıflandırma doğruluğunda piksel tabanlı yaklaşımda %3 obje tabanlı yaklaşımda %7 seviyelerinde artış sağlanabileceği göstermektedir.
- Özellik seçiminde kullanılan algoritmaların performanslarına ilişkin sonuçlar değerlendirildiğinde gerek piksel gerekse obje tabanlı yaklaşımda elde edilen en yüksek sınıflandırma doğruluklarına bir sarmala algoritması olan özyinelemeli özellik seçimi esasına dayalı destek vektör makineleri (DVM-ÖÖE) tarafından seçilen özelliklerle ulaşılmıştır. Diğer taraftan istatistiksel tabanlı filtreleme yaklaşımının yüksek boyutlu veri seti içerisinde uygun özelliklerin belirlenmesinde etkisiz olduğu görülmüştür.
- Özellik seçimi sonucunda oluşturulan farklı boyutlu verilerin kullanımı ile ilgili sonuçlar incelendiğinde, obje ve piksel tabanlı yaklaşımda algoritmaların genellikle 10-75 aralığında değişen bant sayıları ile en yüksek sınıflandırma doğruluğuna ulaştığı sonucuna ulaşılmıştır. Bu sonuç veri seti boyutunun veri seti boyutunun %60-70 düzeyinde azalması ile daha yüksek sınıflandırma sonuçlarına ulaşılabileceğini göstermektedir.
- Obje tabanlı yaklaşımda DVM-ÖÖE ile seçilen 50 özellik analiz edildiğinde özelliklerin 47 tanesinin görüntü objeleri için tanımlanan temel spektral özelliklerden oluştuğu, doku özelliklerinden sadece 7 tanesinin ilk 50 özellik içerisinde girebildiği görülmektedir.
- Seçilen özellikler (bantlar) ele alındığında, WV-2 görüntüsünün mavi, yeşil, kırmızı-1 ve kırmızı-2 bantlarının, WV-2'nin yeni bantlarını kullanarak hesaplanan NDSI, NHFD, NDVI-1 ve NDVI-3 olarak adlandırılan vejetasyon indekslerinin ve ilk üç temel bileşenin problem çözümünde etkili olduğu sonucuna ulaşılmıştır.

- Uygulama sonuçları obje tabanlı yaklaşımın benzer spektral özelliklere sahip arazi örtüsü/kullanım sınıflarının ayırt edilmesi ve tematik harita üretiminde piksel tabanlı yaklaşıma göre %8'e varan düzeylerde daha doğru sonuçlar verdiğini göstermektedir.
- Çalışma sonuçları değerlendirmeye alınan tüm sınıflandırma algoritmalarının sınıflandırma performanslarının obje tabanlı yaklaşımda kullanılmaları durumunda %3-8 seviyelerinde arttığını göstermektedir.
- Algoritmaların performansları incelendiğinde en yakın komşuluk ve karar ağacı algoritmalarının her iki sınıflandırma yaklaşımında da en düşük sınıflandırma performansını sergilediği görülmüştür.
- Sınıflandırma algoritmaları içerisinde destek vektör makineleri ve rotasyon orman algoritmalarının diğer algoritmalara göre üstün bir sınıflandırma performansı göstererek tez kapsamında ele alınan sınıflandırma probleminin çözümünde etkinliği ile öne çıkan algoritmalarlardır.
- Uygulama sonucunda elde edilen tematik haritaların doğruluğu analiz edildiğinde rotasyon orman algoritması ile %91,03 destek vektör makineleri ile %89,56 genel sınıflandırma doğruluğuna ulaşıldığı belirlenmiştir. McNemar's testi sonuçlarına göre RotOR ve DVM ile elde edilen genel doğruluklar arasındaki farkın istatistiksel olarak anlamlı olduğu belirlenmiştir.

Elde edilen bulgular, tez kapsamında önerilen sınıflandırma modeli yaklaşımının yüksek çözünürlüklü uydu görüntüleri üzerinden zeytin ağaçları gibi ekonomik değere sahip ağaç türleri için rekolte tahmini ve ağaç sayımı yapılması gibi önemli uygulamaların gerçekleştirilmesinde etkili ve alternatif bir model olduğunu destekler niteliktedir. Tez önerisinde hedeflenen tüm amaçlara ulaşıldığı, önerilen metodoloji ve yaklaşımın tezin amaçlarına ulaşmada etkili bir yöntem olduğu görülmüştür. Tez kapsamında elde edilen sonuçlardan hareketle sonraki çalışmalarda araştırmacılara yol göstermek amacıyla yüksek çözünürlüklü görüntüler üzerinden detaylı arazi örtüsü ve arazi kullanımının belirlenmesi probleminin çözümü noktasında tavsiye edilen işlem adımları aşağıda maddeler halinde özetlenmiştir.

- Çalışma alanındaki arazi örtüsü/kullanım sınıflarına ilişkin spektral özelliklerin belirlenerek spektral kütüphane oluşturulması önemli avantajlar sağlamaktadır.

- Sınıflandırma işleminin gerçekleştirilmesinde obje tabanlı yaklaşım öncelikli ve ilk tercih olarak dikkate alınmalıdır. Görüntü segmentasyon işleminin gerçekleştirilmesinde tek bir ölçek parametresi yerine, tespit edilen arazi örtüsü/kullanım sınıflarının dağılımına ve içeriğine göre farklı ölçek parametreleri dikkate alınmalıdır.
- Yüksek çözünürlüklü uydu görüntülerinin sadece mevcut spektral özellikleri değil, uydu görüntüsü yardımıyla elde edilebilecek yardımcı verilerde değerlendirmeye alınmalıdır.
- Uydu görüntüsü ve yardımcı verilerin bir araya gelmesi ile oluşan yüksek boyuttaki veri seti kullanımı yerine özyinelemeli özellik seçimi esasına dayalı destek vektör makineleri algoritması ile belirlenen özellikler kullanılmalıdır.
- Veri seti boyutu sınıflandırma algoritmalarının performansını etkileyen en önemli faktörlerden biri olduğundan seçilen özelliklerin ne kadarı ile optimum çözüm sağlandığı araştırılmalıdır.
- Obje tabanlı sınıflandırma işleminin gerçekleştirilmesinde klasik istatistiksel sınıflandırma algoritmaları yerine toplu öğrenme algoritmaları veya destek vektör makineleri gibi ileri sınıflandırma algoritmaları kullanılmalıdır,

Tez kapsamında elde edilen sonuçlar ışığında gelecekte yapılması düşünülenler ve öneriler şu şekilde sıralanabilir:

- WorldView-2 görüntüsü ağaç türlerinin ayırt edilmesi noktasında önemli bir veri kaynağı olmasına karşın belirli ölçüde spektral bilgi sağlayabilmektedir. Bu nedenle sonraki çalışmalarda 2014 ağustos ayında uzaya gönderilen ve WV-2'nin sahip olduğu 8 spektral banda ilave olarak 8 orta kızılötesi (SWIR) bantta daha algılama yapabilen ve daha yüksek konumsal çözünürlükte görüntü sağlayan (1.24m multispektral ve 0.31m pankromatik) yeni nesil WorldView-3 görüntülerinin kullanılması önerilmektedir. Tez kapsamında oluşturulan spektral kütüphane WV-3'ün yeni bantları açısından ele alındığında orta kızılötesi bölgede sahip olduğu yeni bantların değerlendirmeye alınan ağaç türlerinin etkili bir şekilde ayırt edilmeleri noktasında çok daha fazla bilgi sağladığı sonucuna ulaşılmıştır.
- Obje tabanlı sınıflandırma işleminin gerçekleştirilmesinde segmentasyon parametrelerinin seçimine yönelik yeni yaklaşım ve yöntemlerin geliştirilmesi çalışmaların başarısı için önemli bir ihtiyaçtır.

- Obje tabanlı sınıflandırma işleminde görüntü objelerine ilişkin tanımlanan temel spektral özellikler ve doku özelliklerinin yanında, objelerin birbirleriyle olan ilişkileri ve geometrik özelliklerde uygulama değerlendirmeye alınarak daha kompleks sınıflandırma modellerinin etkinliği araştırılmalıdır.
- Obje tabanlı sınıflandırma işleminde temel sınıflandırıcı olarak yeni nesil ileri sınıflandırma algoritmaları, veri madenciliği teknikleri ve makine öğrenme algoritmalarının performanslarının analiz edilmesi önemli bir araştırma konusudur.
- Yardımcı veri seti olarak kullanılabilecek literatürdeki vejetasyon indekslerinin dikkate alınarak sınıflandırma doğruluğu üzerine katkısı araştırılma konusudur.
- Yardımcı veri seti olarak çalışmalarda çoğunlukla ele alınan temel bileşenler analizi yerine son yıllarda doğrusal olmayan veri setleri için daha doğru çözümler ürettiği ifade edilen kernel tabanlı temel bileşenler analizinin kullanımı önemli bir araştırma konusudur.
- Yardımcı veri olarak uydu görüntüsünün mevcut spektral bantları yardımıyla çeşitli görüntü dönüşümleri neticesinde elde edilen veriler yanında, arazinin yüzey özelliklerinin (eğim, yükseklik, bakı vb.) sınıflandırma doğruluğuna etkileri incelenmelidir. Bunun yanında yüzeyin doğal ve yapay özelliklerine ilişkin çok hassas yükseklik bilgisi sağlayan LIDAR verilerinin kullanımı incelenmelidir.
- Arazi örtüsü ve arazi kullanımı kullanımının haritalanması probleminin çözümünde ilgi duyulan doğal ve yapay nesnelerin tümü için spektral özelliklerin belirlenmesi ve uygulamalarda kullanımı incelenmelidir.
- Özellik seçimi noktasında hem özelliklerin önem derecesini hem de optimum özellik boyutunun tespitinde yeni ve gelişmiş algoritmaların kullanılabilirliğinin araştırılması gerekmektedir.



## KAYNAKLAR

- Aguilar, M. A., Saldana, M. M. ve Aguilar, F. J.** (2013). GeoEye-1 and WorldView-2 pan-sharpened imagery for object-based classification in urban environments. *International Journal of Remote Sensing*, **34**, 2583-2606.
- Ahmad, A. ve Dey, L.** (2005). A feature selection technique for classificatory analysis. *Pattern Recognition Letters*, **26**, 43-56.
- Amro, I., Mateos, J., Vega, M., Molina, R. ve Katsaggelos, A. K.** (2011). A survey of classical methods and new trends in pansharpening of multispectral images. *Eurasip Journal on Advances in Signal Processing*.
- Anders, N. S., Seijmonsbergen, A. C. ve Bouten, W.** (2011). Segmentation optimization and stratified object-based analysis for semi-automated geomorphological mapping. *Remote Sensing of Environment*, **115**, 2976-2985.
- Asmaryan, S., Warner, T. A., Muradyan, V. ve Nersisyan, G.** (2013). Mapping tree stress associated with urban pollution using the WorldView-2 Red Edge band. *Remote Sensing Letters*, **4**, 200-209.
- Baatz, M. ve Schape, A.** (2000). Multi resolution segmentation-an optimization approach for high quality multi scale image segmentation. *Angewandte Geographische Informations verarbeitung XII*. Karlsruhe, Germany, pp. 12-23.
- Baccianella, S., Esuli, A. ve Sebastiani, F.** (2014). Feature Selection for Ordinal Text Classification. *Neural Computation*, **26**, 557-591.
- Bannari, A., Morin, D. ve Bonn, F.** (1995). A review of vegetation indices, *Remote Sensing Reviews*, **13**, 95-120.
- Bellman, R.E.** (1961). *Adaptive Control Processes: A Guided Tour*, Princeton University Press, Princeton, NJ.
- Benz, U. C., Hofmann, P., Willhauck, G., Lingenfelder, I. ve Heynen, M.** (2004). Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. *ISPRS Journal of Photogrammetry and Remote Sensing*, **58**, 239-258.
- Biesiada, J. ve Duch. W.** (2007). Feature selection for high-dimensional data, a pearson redundancy based filter. *Computer Recognition Systems 2*, **4**, 5, 242-249.
- Blaschke, T.** (2010). Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, **65**, 2-16.
- Blum, A. L. ve Langley, P.** (1997). Selection of relevant features and examples in machine learning. *Artificial Intelligence*, **97**, 245-271.

- Breiman L., Friedman J.H., Olshen R.A. ve Stone C.J.** (1984). *Classification and Regression Trees*. Wadsworth Inc., Monterey, Calif, USA.
- Breiman, L.** (1996). Bagging predictors. *Machine Learning*, **24**, 123-140.
- Breiman, L.** (2001). Random forests. *Machine Learning*, **45**, 5-32.
- Campbell, J.B ve Wynne, R.H.** (2011). *Introduction to Remote Sensing*. Fifth edition, The Guilford Press, NY, USA.
- Camps-Valls, G. ve Bruzzone, L.** (2009) *Kernel methods for Remote Sensing Data Analysis*. Wiley & Sons, UK.
- Camps-Valls, G., Tuia, D., Gomez-Chova, L., Jimenez, S. ve Malo, J.** (2011). *Remote Sensing Image Processing*, Collection ‘Synthesis Lectures on Image, Video, and Multimedia Processing’, Al Bovik, Ed., Morgan & Claypool Publishers, LaPorte, CO, USA.
- Canty, M.J.** (2014). *Image Analysis, Classification and Change Detection in Remote Sensing: With Algorithms for ENVI/IDL and Python*, Third Edition, CRC Press, Boca Raton, USA.
- Carleer, A. ve Wolff, E.** (2004). Exploitation of very high resolution satellite data for tree species identification. *Photogrammetric Engineering and Remote Sensing*, **70**, 135-140.
- Chi, M. M., Feng, R. ve Bruzzone, L.** (2008). Classification of hyperspectral remote-sensing data with primal SVM for small-sized training dataset problem. *Advances in Space Research*, **41**, 1793-1799.
- Cho, M. A., Mathieu, R., Asner, G. P., Naidoo, L., van Aardt, J., Ramoelo, A., Debba, P., Wessels, K., Main, R., et al.** (2012). Mapping tree species composition in South African savannas using an integrated airborne spectral and LiDAR system. *Remote Sensing of Environment*, **125**, 214-226.
- Clark, R.N., Gallagher, A.J. ve Swayze, G.A.** (1990). Material absorption band depth mapping of imaging spectrometer data using the complete band shape least-squares algorithm simultaneously fit to multiple spectral features from multiple materials: in Proceedings of the Third Airborne Visible/Infrared Imaging Spectrometer (AVIRIS) Workshop, JPL Publication 90-54, pp. 176 - 186.
- Collin, A., Archambault, P. ve Planes, S.** (2013). Bridging Ridge-to-Reef Patches: Seamless Classification of the Coast Using Very High Resolution Satellite. *Remote Sensing*, **5**, 3583-3610.
- Cortes, C. ve Vapnik, V.** (1995). Support-Vector Networks. *Machine Learning*, **20**, 273-297.
- Çölkesen, İ. ve Kavzoğlu, T.** (2010). Farklı Boyutta Eğitim Örnekleri İçin Destek Vektör Makinelerinin Sınıflandırma Performansının Analizi, 3. Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu (UZALCBS'2010), 11-13 Ekim 2010, Gebze, Kocaeli.
- Çölkesen, İ. ve Yomralıoğlu, T.** (2014). Arazi örtüsü ve kullanımının haritalanmasında WorldView-2 uydu görüntüsü ve yardımcı verilerin kullanımı, *Harita Dergisi*, **152**, 12-24.

- Çölkesen, İ.** (2009). *Uzaktan algılamada ileri sınıflandırma tekniklerinin karşılaştırılması ve analizi*, (yüksek lisans tezi), GYTE, Fen Bilimleri Enstitüsü.
- Çölkesen, İ., Yomralıoğlu T. ve Kavzoğlu, T.** (2014). Rotasyon Orman Algoritması İle Yüksek Çözünürlüklü Multispektral Uydu Görüntülerinin Sınıflandırılması, 5. Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu (UZALCBS'2014), 14-17 Ekim 2014, İstanbul.
- Dalponte, M., Bruzzone, L. ve Gianelle, D.** (2012). Tree species classification in the Southern Alps based on the fusion of very high geometrical resolution multispectral/hyperspectral images and LiDAR data. *Remote Sensing of Environment*, **123**, 258-270.
- De Fries, R. S., Hansen, M., Townshend, J. R. G. ve Sohlberg, R.** (1998). Global land cover classifications at 8 km spatial resolution: the use of training data derived from Landsat imagery in decision tree classifiers. *International Journal of Remote Sensing*, **19**, 3141-3168.
- De Pinho, C. M. D., Fonseca, L. M. G., Korting, T. S., De Almeida, C. M. ve Kux, H. J. H.** (2012). Land-cover classification of an intra-urban environment using high-resolution images and object-based image analysis. *International Journal of Remote Sensing*, **33**, 5973-5995.
- Definiens (2012).** Definiens Developer XD 2.0.4 User Guide.
- DeFries R., Hansen M., Townshend J.R.G. ve Sohlberg R.** (1998). Global land cover classifications at 8 km spatial resolution: the use of training data derived from Landsat imagery in decision tree classifiers”, *International Journal of Remote Sensing*, **19**, 3141–3168.
- Deng, S. Q., Katoh, M., Guan, Q. W., Yin, N. ve Li, M. Y.** (2014). Interpretation of Forest Resources at the Individual Tree Level at Purple Mountain, Nanjing City, China, Using WorldView-2 Imagery by Combining GPS, RS and GIS Technologies. *Remote Sensing*, **6**, 87-110.
- Dietterich, T. G.** (2000). An experimental comparison of three methods for constructing ensembles of decision trees: Bagging, boosting, and randomization. *Machine Learning*, **40**, 139-157.
- Diez-Pastor, J. F., Garcia-Osorio, C. ve Rodriguez, J. J.** (2014). Tree ensemble construction using a GRASP-based heuristic and annealed randomness. *Information Fusion*, **20**, 189-202.
- Ding, Y. J., Li, M. Z., Li, S. Q. ve An, D. K.** (2010). Predicting chlorophyll content of Greenhouse Tomato with ground-based remote sensing. *Multispectral, Hyperspectral, and Ultraspectral Remote Sensing Technology, Techniques, and Applications Iii*, **7857**.
- Domingos, P. ve Pazzani, M.** (1997). On the optimality of the simple Bayesian classifier under zero-one loss. *Machine Learning*, **29**, 103-130.
- Du, P. J., Xia, J. S., Zhang, W., Tan, K., Liu, Y. ve Liu, S. C.** (2012). Multiple classifier system for remote sensing image classification: A review. *Sensors*, **12**, 4764-4792.

- Du, P.J., Liu P. and Luo, Y.** (2009). Urban thermal environment simulation and prediction based on remote sensing and GIS. *2009 IEEE International Geoscience and Remote Sensing Symposium*, 1-5, 2357-2360.
- Du, Q., Younan, N. H., King, R. ve Shah, V. P.** (2007). On the performance evaluation of pan-sharpening techniques. *IEEE Geoscience and Remote Sensing Letters*, **4**, 518-522.
- Duda, R. O. ve Hart, P. E.** (1973). *Pattern classification and scene analysis*. John Wiley & Sons, New York, USA.
- Eckert, S.** (2012). Improved Forest Biomass and Carbon Estimations Using Texture Measures from WorldView-2 Satellite Data. *Remote Sensing*, **4**, 810-829.
- Fassnacht, F. E., Neumann, C., Forster, M., Buddenbaum, H., Ghosh, A., Clasen, A., Joshi, P. K. ve Koch, B.** (2014). Comparison of Feature Reduction Algorithms for Classifying Tree Species With Hyperspectral Data on Three Central European Test Sites. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, **7**, 2547-2561.
- Feret, J. B. ve Asner, G. P.** (2014). Mapping tropical forest canopy diversity using high-fidelity imaging spectroscopy. *Ecological Applications*, **24**, 1289-1296.
- Fernandes, M. R., Aguiar, F. C., Silva, J. M. N., Ferreira, M. T. ve Pereira, J. M. C.** (2013). Spectral discrimination of giant reed (*Arundo donax* L.): A seasonal study in riparian areas. *ISPRS Journal of Photogrammetry and Remote Sensing*, **80**, 80-90.
- Fernandes, M. R., Aguiar, F. C., Silva, J. M. N., Ferreira, M. T. ve Pereira, J. M. C.** (2014). Optimal attributes for the object based detection of giant reed in riparian habitats: A comparative study between Airborne High Spatial Resolution and WorldView-2 imagery. *International Journal of Applied Earth Observation and Geoinformation*, **32**, 79-91.
- Fisher, P.** (1997). The pixel: A snare and a delusion. *International Journal of Remote Sensing*, **18**, 679-685.
- Foody, G. M.** (2004). Thematic map comparison: Evaluating the statistical significance of differences in classification accuracy. *Photogrammetric Engineering and Remote Sensing*, **70**, 627-633.
- Foody, G. M., Mathur, A., Sanchez-Hernandez, C. ve Boyd, D. S.** (2006). Training set size requirements for the classification of a specific class. *Remote Sensing of Environment*, **104**, 1-14.
- Forster, M., Frick, A., Walentowski, H. ve Kleinschmit, B.** (2008). Approaches to utilising QuickBird data for the monitoring of NATURA 2000 habitats. *Community Ecology*, **9**, 155-168.
- Franklin, S. E., Hall, R. J., Moskal, L. M., Maudie, A. J. ve Lavigne, M. B.** (2000). Incorporating texture into classification of forest species composition from airborne multispectral images. *International Journal of Remote Sensing*, **21**, 61-79.

- Freund, Y. ve Schapire, R. E.** (1996). Experiments with a new boosting algorithm. In: Saitta, L. (Ed.), *Proceedings of the Thirteenth International Conference on Machine Learning (ICML-96)*. Morgan Kaufmann, 148-156.
- Gao, J. X., Chen, Y. M., Lu, S. H., Feng, C. Y., Chang, X. L., Ye, S. X. ve Liu, J. D.** (2012). A ground spectral model for estimating biomass at the peak of the growing season in Hulunbeier grassland, Inner Mongolia, China. *International Journal of Remote Sensing*, **33**, 4029-4043.
- Garrity, S. R., Allen, C. D., Brumby, S. P., Gangodagamage, C., McDowell, N. G. ve Cai, D. M.** (2013). Quantifying tree mortality in a mixed species woodland using multitemporal high spatial resolution satellite imagery. *Remote Sensing of Environment*, **129**, 54-65.
- Ghosh, A. ve Joshi, P. K.** (2014). A comparison of selected classification algorithms for mapping bamboo patches in lower Gangetic plains using very high resolution WorldView 2 imagery. *International Journal of Applied Earth Observation and Geoinformation*, **26**, 298-311.
- Gidudu, A. ve Ruther, H.** (2007). Comparison of feature selection techniques for SVM classification, in Proc. 10th Int. Symp. Phys. Meas. Spectral Signatures Remote Sens., vol. XXXVI, Intl. Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, M. E. Schaepman, S. Liang, N. E. Groot, and M. Kneubühler, Eds., Davos, Switzerland, pp. 258–263.
- Goltz, E., Arcoverde, G. F. B., de Aguiar, D. A., Rudorff, B. F. T. ve Maeda, E. E.** (2009). Data mining by decision tree for object oriented classification of the sugar cane cut kinds. *2009 IEEE International Geoscience and Remote Sensing Symposium*, **1-5**, 3830-3833.
- Gualtieri, J.A.** (2009). The support vector machine (SVM) algorithm for supervised classification of hyperspectral remote sensing data,” in *Kernel Methods for Remote Sensing Data Analysis*, G. Camps-Valls and L. Bruzzone, Eds. Chichester, U.K.: Wiley.
- Guyon, I., Weston, J., Barnhill, S. ve Vapnik, V.** (2002). Gene selection for cancer classification using support vector machines. *Machine Learning*, **46**, 389-422.
- Hanna, S. H. S. ve Rethwisch, M. D.** (2004). Characteristics of AVIRIS bands measurements in agricultural crops at Blythe area, California: IV. Studies on cotton varieties spectral data. *Remote Sensing for Agriculture, Ecosystems, and Hydrology V*, **5232**, 52-82.
- Haralick, R.M., Shanmugam, K. ve Dinstein, I.** (1973). Textural features for image classification. *IEEE Transactions on Systems, Man and Cybernetics*, **3**, 610-621.
- He, F. L. ve Legendre, P.** (2002). Species diversity patterns derived from species-area models. *Ecology*, **83**, 1185-1198.
- Heumann, B. W.** (2011). An Object-Based Classification of Mangroves Using a Hybrid Decision Tree-Support Vector Machine Approach. *Remote Sensing*, **3**, 2440-2460.

- Hirata, Y., Tabuchi, R., Patanaponpaiboon, P., Pongparn, S., Yoneda, R. ve Fujioka, Y.** (2014). Estimation of aboveground biomass in mangrove forests using high-resolution satellite data. *Journal of Forest Research*, **19**, 34-41.
- Holte, R. C.** (1993). Very Simple Classification Rules Perform Well on Most Commonly Used Datasets. *Machine Learning*, **11**, 63-91.
- Hu, G. Y., Dong, Z. B., Wei, Z. H. ve Lu, J. F.** (2010). Land use and land cover change monitoring in the Zoige Wetland by remote sensing. *Sixth International Symposium on Digital Earth: Data Processing and Applications*, **7841**, 710.
- Huang, C., Davis, L. S. ve Townshend, J. R. G.** (2002). An assessment of support vector machines for land cover classification. *International Journal of Remote Sensing*, **23**, 725-749.
- Huang, X., Zhang, L. P. ve Zhu, T. T.** (2014). Building Change Detection From Multitemporal High-Resolution Remotely Sensed Images Based on a Morphological Building Index. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, **7**, 105-115.
- Hughes, G.F.** (1968). On the mean accuracy of statistical pattern recognizers, *IEEE Transactions on Information Theory*, **14**, 55-63.
- Immitzer, M., Atzberger, C. ve Koukal, T.** (2012). Tree Species Classification with Random Forest Using Very High Spatial Resolution 8-Band WorldView-2 Satellite Data. *Remote Sensing*, **4**, 2661-2693.
- Jafari, R. ve Lewis, M. M.** (2012). Arid land characterisation with EO-1 Hyperion hyperspectral data. *International Journal of Applied Earth Observation and Geoinformation*, **19**, 298-307.
- Jakubowski, M. K., Li, W. K., Guo, Q. H. ve Kelly, M.** (2013). Delineating Individual Trees from Lidar Data: A Comparison of Vector- and Raster-based Segmentation Approaches. *Remote Sensing*, **5**, 4163-4186.
- Japkowicz, N. ve Shah, M.** (2011). *Evaluating Learning Algorithm: A classification Perspective*, Cambridge University Press, New York, USA.
- Jha, R. K., Karnataka, H. C. ve Pant, D. N.** (2009). Forest landuse planning for Thano range, Dehradun forest division, Uttaranchal. *Range Management and Agroforestry*, **30**, 72-77.
- Johansen, K. ve Phinn, S.** (2006). Mapping structural parameters and species composition of riparian vegetation using IKONOS and landsat ETM plus data in Australian tropical savannahs. *Photogrammetric Engineering and Remote Sensing*, **72**, 71-80.
- John, G.H. ve Langley, P.** (1995). Estimating continuous distributions in Bayesian classifiers. In: Eleventh Conference on Uncertainty in Artificial Intelligence, San Mateo, 338-345.
- Johnson, B. A.** (2013). High-resolution urban land-cover classification using a competitive multi-scale object-based approach. *Remote Sensing Letters*, **4**, 131-140.

- Kamal, M., Phinn, S. ve Johansen, K.** (2014). Characterizing the Spatial Structure of Mangrove Features for Optimizing Image-Based Mangrove Mapping. *Remote Sensing*, **6**, 984-1006.
- Karathanassi, V., Kolokousis, P. ve Ioannidou, S.** (2007). A comparison study on fusion methods using evaluation indicators. *International Journal of Remote Sensing*, **28**, 2309-2341.
- Katoh, M.** (2004). Classifying tree species in a northern mixed forest using high-resolution IKONOS data. *Journal of Forest Research*, **9**, 7-14.
- Kavzoglu, T. ve Colkesen, I.** (2012). The effects of training set size for the performance of support vector machines and decision trees, Proceedings of 10th International Symposium on Spatial Accuracy Assessment in Natural Resources and Environmental Sciences (ACCURACY2012), 10-13 July, Florianópolis, SC, Brazil, 127-132.
- Kavzoglu, T. ve Colkesen, I.** (2009). A kernel functions analysis for support vector machines for land cover classification. *International Journal of Applied Earth Observation and Geoinformation*, **11**, 352-359.
- Kavzoglu, T. ve Colkesen, I.** (2013). An assessment of the effectiveness of a rotation forest ensemble for land-use and land-cover mapping. *International Journal of Remote Sensing*, **34**, 4224-4241.
- Kavzoglu, T. ve Mather, P. M.** (2003). The use of backpropagating artificial neural networks in land cover classification. *International Journal of Remote Sensing*, **24**, 4907-4938.
- Kavzoglu, T. ve Reis, S.** (2008). Performance analysis of maximum likelihood and artificial neural network classifiers for training sets with mixed pixels. *Giscience & Remote Sensing*, **45**, 330-342.
- Kavzoğlu, T. ve Çölkesen, İ.** (2010). Destek vektör makineleri ile uydu görüntülerinin sınıflandırılmasında kernel fonksiyonlarının etkilerinin incelenmesi, *Harita Dergisi*, **144**, 73-82, (2010).
- Kavzoğlu, T. ve Çölkesen, İ.** (2010), Karar ağaçları ile uydu görüntülerinin sınıflandırılması: Kocaeli örneği, *Harita Teknolojileri Elektronik Dergisi*, **2**, 36-45.
- Kayitakire, F., Hamel, C. ve Defourny, P.** (2006). Retrieving forest structure variables based on image texture analysis and IKONOS-2 imagery. *Remote Sensing of Environment*, **102**, 390-401.
- Kira, K. ve Rendell, L.A.** (1992). The feature selection problem: Traditional methods and a new algorithm, in Proc. of the Tenth National Conference on Artificial Intelligence, pp. 129-134.
- Kohavi, R. ve John, G. H.** (1997). Wrappers for feature subset selection. *Artificial Intelligence*, **97**, 273-324.
- Kononenko, I.** (1994). Estimating Attributes: Analysis and Extensions of RELIEF European Conference on Machine Learning, Catania, Italy, pp. 171-182.
- Kumar, V. ve Minz, S.** (2014). Feature selection: A literature review, *Smart Computing Review*, **4**, 211-229.

- Kunwar, P., Kachhwaha, T. S., Kumar, A., Agrawal, A. K., Singh, A. N. ve Mendiratta, N.** (2010). Use of high-resolution IKONOS data and GIS technique for transformation of landuse/landcover for sustainable development. *Current Science*, **98**, 204-212.
- Landgrebe, D.A.** (2003). *Signal Theory Methods in Multispectral Remote Sensing*. Wiley, Hoboken, NJ.
- Lee, K. S., Kook, M. J., Shin, J. I., Kim, S. H. ve Kim, T. G.** (2007). Spectral characteristics of forest vegetation in moderate drought condition observed by laboratory measurements and spaceborne hyperspectral data. *Photogrammetric Engineering and Remote Sensing*, **73**, 1121-1127.
- Li, H., Lee, W. S., Wang, K., Ehsani, R. ve Yang, C. H.** (2014). 'Extended spectral angle mapping (ESAM)' for citrus greening disease detection using airborne hyperspectral imaging. *Precision Agriculture*, **15**, 162-183.
- Li, M. Z., Zhang, X. J., Zhang, Y., Zhao, P. ve Zhang, J. P.** (2005). Investigation of crop growth condition with hyperspectral reflectance based on ground-based remote sensing. *Multispectral and Hyperspectral Remote Sensing Instruments and Applications Ii*, **5655**, 301-308.
- Li, M., Zang, S. Y., Zhang, B., Li, S. S. ve Wu, C. S.** (2014). A Review of Remote Sensing Image Classification Techniques: the Role of Spatio-contextual Information. *European Journal of Remote Sensing*, **47**, 389-411.
- Li, S. J., Wu, H., Wan, D. S. ve Zhu, J. L.** (2011). An effective feature selection method for hyperspectral image classification based on genetic algorithm and support vector machine. *Knowledge-Based Systems*, **24**, 40-48.
- Lillesand, T.M., Kiefer, R.W. ve Chipman, J.W.** (2007). *Remote Sensing and Image Interpretation*. 6th Edition, John Wiley & Sons., New York, USA.
- Liu, H. ve Setiono, R.** (1996). A probabilistic approach to feature selection-a filter solution. In proceedings of 13th International Conference on Machine Learning (ICML96).
- Liu, J.G. ve Mason, P.J.** (2009). *Essential Image Processing and GIS for Remote Sensing*, John Wiley & Sons., New York, USA.
- Liu, X., Zhu, W. Q., Yang, X. Q. ve Pan, Y. Z.** (2006). Modeling of Population Density Based on GIS and RS. *2006 IEEE International Geoscience and Remote Sensing Symposium, Vols 1-8*, 1431-1434.
- Low, F., Michel, U., Dech, S. ve Conrad, C.** (2013). Impact of feature selection on the accuracy and spatial uncertainty of per-field crop classification using Support Vector Machines. *ISPRS Journal of Photogrammetry and Remote Sensing*, **85**, 102-119.
- Lu, D. S., Hetrick, S. ve Moran, E.** (2010). Land Cover Classification in a Complex Urban-Rural Landscape with QuickBird Imagery. *Photogrammetric Engineering and Remote Sensing*, **76**, 1159-1168.



- Lu, D. S., Hetrick, S. ve Moran, E.** (2011). Impervious surface mapping with Quickbird imagery. *International Journal of Remote Sensing*, **32**, 2519-2533.
- Lu, D. ve Weng, Q.** (2007). A survey of image classification methods and techniques for improving classification performance. *International Journal of Remote Sensing*, **28**, 823-870.
- Maktav, D. ve Sunar, F.** (1991). *Uzaktan algılama: Kantitatif yaklaşım*. Hürriyet Ofset A.Ş., İstanbul.
- Mather, P.M. ve Koch, M.** (2011). *Computer Processing of Remotely-Sensed Images: An Introduction*. Fourth Edition. Wiley-Blackwell, Chichester, UK.
- Mathur, A. ve Foody, G. M.** (2008). Multiclass and binary SVM classification: Implications for training and classification users. *IEEE Geoscience and Remote Sensing Letters*, **5**, 241-245.
- Maudes, J., Rodriguez, J. J., Garcia-Osorio, C. ve Garcia-Pedrajas, N.** (2012). Random feature weights for decision tree ensemble construction. *Information Fusion*, **13**, 20-30.
- Melgani, F. ve Bruzzone, L.** (2004). Classification of hyperspectral remote sensing images with support vector machines. *IEEE Transactions on Geoscience and Remote Sensing*, **42**, 1778-1790.
- Mercier, G. ve Lennon, M.** (2003). Support vector machines for hyperspectral image classification with spectral-based kernels. *IGARSS 2003: IEEE International Geoscience and Remote Sensing Symposium, Vols I - Vii, Proceedings*, 288-290.
- Mianji, F. A. ve Zhang, Y.** (2011). Robust Hyperspectral Classification Using Relevance Vector Machine. *IEEE Transactions on Geoscience and Remote Sensing*, **49**, 2100-2112.
- Mingers J.** (1989). An empirical comparison of pruning methods for decision tree induction, *Machine Learning*, **4**, 227-243.
- Mountrakis, G., Im, J. ve Ogole, C.** (2011). Support vector machines in remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, **66**, 247-259.
- Mukherjee, J., Gebru, G., Sood, A., Mahey, R. K., Bal, S. K., Singh, H. ve Sidhu, P. K.** (2010). Wheat yield and acreage prediction using LISS-III and AWiFS sensors data of indian remote sensing satellite of Rupnager district of Punjab, India. *Rivista Italiana Di Telerilevamento*, **42**, 115-127.
- Mwangi, B., Tian, T. S. ve Soares, J. C.** (2014). A Review of Feature Reduction Techniques in Neuroimaging. *Neuroinformatics*, **12**, 229-244.
- Myint, S. W., Gober, P., Brazel, A., Grossman-Clarke, S. ve Weng, Q. H.** (2011). Per-pixel vs. object-based classification of urban land cover extraction using high spatial resolution imagery. *Remote Sensing of Environment*, **115**, 1145-1161.

- Nag, P. ve Kudrat, M.** (1998). *Digital Remote Sensing*. Concept Publishing Company, New Delhi, India.
- Navulur, K.** (2007). *Multispectral Image Analysis Using the Object-Oriented Paradigm*, CRC Press, Boca Raton, USA.
- Opitz, D. W. ve Maclin, R. F.** (1997). An empirical evaluation of bagging and boosting for artificial neural networks. *1997 IEEE International Conference on Neural Networks, Vols 1-4*, 1401-1405.
- Osuna, E. E., Freund, R. ve Girosi, F.** (1997). Support vector machines: Training and applications, *Artificial In-telligence Laboratory Technical Report*, A.I. Memo 1602-144, Massachusetts Institute of Technology, USA.
- Ozdemir, I.** (2008). Estimating stem volume by tree crown area and tree shadow area extracted from pan-sharpened Quickbird imagery in open Crimean juniper forests. *International Journal of Remote Sensing*, **29**, 5643-5655.
- Ozdemir, I. ve Karnieli, A.** (2011). Predicting forest structural parameters using the image texture derived from WorldView-2 multispectral imagery in a dryland forest, Israel. *International Journal of Applied Earth Observation and Geoinformation*, **13**, 701-710.
- Pal, M.** (2005). Random forest classifier for remote sensing classification. *International Journal of Remote Sensing*, **26**, 217-222.
- Pal, M.** (2008). Ensemble of support vector machines for land cover classification. *International Journal of Remote Sensing*, **29**, 3043-3049.
- Pal, M. ve Foody, G. M.** (2010). Feature Selection for Classification of Hyperspectral Data by SVM. *IEEE Transactions on Geoscience and Remote Sensing*, **48**, 2297-2307.
- Pal, M. ve Mather, P. M.** (2003). An assessment of the effectiveness of decision tree methods for land cover classification. *Remote Sensing of Environment*, **86**, 554-565.
- Pal, M. ve Mather, P. M.** (2005). Support vector machines for classification in remote sensing. *International Journal of Remote Sensing*, **26**, 1007-1011.
- Patino, J. E. ve Duque, J. C.** (2013). A review of regional science applications of satellite remote sensing in urban settings. *Computers Environment and Urban Systems*, **37**, 1-17.
- Payero, J. O., Neale, C. M. U. ve Wright, J. L.** (2004). Comparison of eleven vegetation indices for estimating plant height of alfalfa and grass. *Applied Engineering in Agriculture*, **20**, 385-393.
- Peerbhay, K. Y., Mutanga, O. ve Ismail, R.** (2014). Investigating the Capability of Few Strategically Placed Worldview-2 Multispectral Bands to Discriminate Forest Species in KwaZulu-Natal, South Africa. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, **7**, 307-316.
- Plackett, R. L.** (1983). Pearson, Karl and the Chi-Squared Test. *International Statistical Review*, **51**, 59-72.

- Pohl, C. ve van Genderen, J. L.** (1998). Multisensor image fusion in remote sensing: concepts, methods and applications. *International Journal of Remote Sensing*, **19**, 823-854.
- Pu, R. L. ve Landry, S.** (2012). A comparative analysis of high spatial resolution IKONOS and WorldView-2 imagery for mapping urban tree species. *Remote Sensing of Environment*, **124**, 516-533.
- Quinlan J.R.** (1993). *C4.5: Programs for Machine Learning*. Morgan Kaufmann, San Mateo, CA.
- Reddy, C. S., Khuroo, A. A., Krishna, P. H., Saranya, K. R. L., Jha, C. S. ve Dadhwal, V. K.** (2014). Threat evaluation for biodiversity conservation of forest ecosystems using geospatial techniques: A case study of Odisha, India. *Ecological Engineering*, **69**, 287-303.
- Ren, H. Y., Zhuang, D. F., Pan, J. J., Shi, X. Z. ve Wang, H. J.** (2008). Hyperspectral remote sensing to monitor vegetation stress. *Journal of Soils and Sediments*, **8**, 323-326.
- Rencz, A.N. ve Ryerson, R.A.** (1999). *Manual of Remote Sensing*, Remote Sensing for the Earth Sciences, John Wiley & Sons, New York, USA.
- Richards, J.A.** (2013). *Remote Sensing Digital Image Analysis: An Introduction*. Fifth Edition, Springer-Verlag, New York, USA.
- Rish, I.** (2001). An empirical study of the naïve Bayes classifier, International Joint Conferences on Artificial Intelligence.
- Robnik-Sikonja, M. ve Kononenko, I.** (2003). Theoretical and empirical analysis of ReliefF and RReliefF. *Machine Learning*, **53**, 23-69.
- Rodriguez, J. J. ve Kuncheva, L. I.** (2006). Rotation forest: A new classifier ensemble method. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **28**, 1619-1630.
- Rodriguez, J. J., Garcia-Osorio, C. ve Maudes, J.** (2010). Forests of nested dichotomies. *Pattern Recognition Letters*, **31**, 125-132.
- Rodriguez-Galiano, V. F. ve Chica-Rivas, M.** (2014). Evaluation of different machine learning methods for land cover mapping of a Mediterranean area using multi-seasonal Landsat images and Digital Terrain Models. *International Journal of Digital Earth*, **7**, 492-509.
- Rogan, J., Franklin, J., Stow, D., Miller, J., Woodcock, C. ve Roberts, D.** (2008). Mapping land-cover modifications over large areas: A comparison of machine learning algorithms. *Remote Sensing of Environment*, **112**, 2272-2283.
- Rokade, V. M., Kundal, P. ve Joshi, A. K.** (2007). Groundwater potential modelling through remote sensing and GIS: A case study from Rajura taluka, Chandrapur district, Maharashtra. *Journal of the Geological Society of India*, **69**, 943-948.
- Royer, P. D., Cobb, N. S., Clifford, M. J., Huang, C. Y., Breshears, D. D., Adams, H. D. ve Villegas, J. C.** (2011). Extreme climatic event-triggered overstorey vegetation loss increases understorey solar input

regionally: primary and secondary ecological implications. *Journal of Ecology*, **99**, 714-723.

- Saeys, Y., Inza, I. ve Larranaga, P.** (2007). A review of feature selection techniques in bioinformatics. *Bioinformatics*, **23**, 2507-2517.
- Safavian, S. R. ve Landgrebe, D.** (1991). A Survey of Decision Tree Classifier Methodology. *IEEE Transactions on Systems Man and Cybernetics*, **21**, 660-674.
- Sarp, G.** (2014). Spectral and spatial quality analysis of pan-sharpening algorithms: A case study in Istanbul. *European Journal of Remote Sensing*, **47**, 19-28.
- Shamsoddini, A., Trinder, J. C. ve Turner, R.** (2013). Pine plantation structure mapping using WorldView-2 multispectral image. *International Journal of Remote Sensing*, **34**, 3986-4007.
- Silvestri, S. ve Omri, M.** (2008). A method for the remote sensing identification of uncontrolled landfills: formulation and validation. *International Journal of Remote Sensing*, **29**, 975-989.
- Strasser, T., Lang, S., Riedler, B., Pernkopf, L. ve Paccagnel, K.** (2014). Multiscale object feature library for habitat quality monitoring in riparian forests. *IEEE Geoscience and Remote Sensing Letters*, **11**, 559-563.
- Swain P.H. ve Hauska H.** (1977). Decision tree classifier - design and potential, *IEEE Transactions on Geoscience and Remote Sensing*, **15**, 142-147.
- Swain, P. H., and Davis, S. M.** (1978). *Remote Sensing: The Quantitative Approach*. McGraw-Hill, New York, USA.
- Tang, A. P., Ran, C., Wang, L. F., Gai, L. H. ve Dai, M.** (2009). Intelligent Digital System in Urban Natural Hazard Mitigation. *2009 WRI World Congress on Software Engineering, Vol 2, Proceedings*, 355-359.
- Tehrany, M. S., Pradhan, B. ve Jebuv, M. N.** (2014). A comparative assessment between object and pixel-based classification approachMAes for land-use/land-cover mapping using SPOT 5 imagery. *Geocarto International*, **29**, 351-369.
- Theodoridis, S. ve Koutroumbas, K.** (2009). *Pattern Recognition*, 4th edition, Academic Press, Waltham, MA, USA.
- Trias-Sanz, R., Stamon, G. ve Louchet, J.** (2008). Using colour, texture, and hierarchial segmentation for high-resolution remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, **63**, 156-168.
- Tso B. ve Mather, P.M.** (2009). *Classification Methods for Remotely Sensed Data*. Second Edition, CRC Press, Boca Raton, FL.
- Updike, T. ve Comp, C.** (2010). Radiometric use of WorldView-2 Imagery, Technical Note, Longmont, CO: DigitalGlobe.
- Van Beek, J., Tits, L., Somers, B. ve Coppin, P.** (2013). Stem Water Potential Monitoring in Pear Orchards through WorldView-2 Multispectral Imagery. *Remote Sensing*, **5**, 6647-6666.

- Vapnik, V. N.** (1995). *The nature of statistical learning theory*. Springer-Verlag, New York, USA.
- Wang, C. W. ve Hunter, A.** (2010). A low variance error boosting algorithm. *Applied Intelligence*, **33**, 357-369.
- Waser, L. T., Kuchler, M., Jutte, K. ve Stampfer, T.** (2014). Evaluating the Potential of WorldView-2 Data to Classify Tree Species and Different Levels of Ash Mortality. *Remote Sensing*, **6**, 4515-4545.
- Webb, G. I.** (2000). MultiBoosting: A technique for combining boosting and wagging. *Machine Learning*, **40**, 159-196.
- Wieland, M. ve Pittore, M.** (2014). Performance Evaluation of Machine Learning Algorithms for Urban Pattern Recognition from Multi-spectral Satellite Images. *Remote Sensing*, **6**, 2912-2939.
- Witten, L.H., Frank, E. ve Hall, A.M.** (2011). *Data Mining: Practical Machine Learning Tools and Techniques*. Third Edition, Morgan Kaufman Publishers, Burlington, USA.
- Wu, B., Chen, C. C., Kechadi, T. M. ve Sun, L. Y.** (2013). A comparative evaluation of filter-based feature selection methods for hyper-spectral band selection. *International Journal of Remote Sensing*, **34**, 7974-7990.
- Xia, J. S., Du, P. J., He, X. Y. ve Chanussot, J.** (2014). Hyperspectral Remote Sensing Image Classification Based on Rotation Forest. *IEEE Geoscience and Remote Sensing Letters*, **11**, 239-243.
- Xian, G., Homer, C., Meyer, D. ve Granneman, B.** (2013). An approach for characterizing the distribution of shrubland ecosystem components as continuous fields as part of NLCD. *ISPRS Journal of Photogrammetry and Remote Sensing*, **86**, 136-149.
- Xie, J. Y. ve Wang, C. X.** (2011). Using support vector machines with a novel hybrid feature selection method for diagnosis of erythemato-squamous diseases. *Expert Systems with Applications*, **38**, 5809-5815.
- Xu, H. Q.** (2013). Rule-based impervious surface mapping using high spatial resolution imagery. *International Journal of Remote Sensing*, **34**, 27-44.
- Xu, K., Zhang, X. X., Chen, B., Hua, K., Zheng, K. D. ve Wu, T.** (2011). Based on MODIS NDVI data to monitor the growing season of the deciduous forest in Beijing, China. *Earth Resources and Environmental Remote Sensing/Gis Applications Ii*, **8181**.
- Yang, S. Y., Wang, M. ve Jiao, L. C.** (2012). Fusion of multispectral and panchromatic images based on support value transform and adaptive principal component analysis. *Information Fusion*, **13**, 177-184.
- Yang, X. ve Li, J.** (2012), *Advances in Mapping from Remote Sensor Imagery: Techniques and Applications*. CRC Press, New York, USA.
- Yu, L. ve Liu, H.** (2003). Feature Selection for High-Dimensional Data: A Fast Correlation-Based Filter Solution. ICML 2003, 856-863, August 21-24, 2003, Washington DC, USA.

- Zhang, L., Jia, K., Li, X. S., Yuan, Q. Z. ve Zhao, X. F.** (2014). Multi-scale segmentation approach for object-based land-cover classification using high-resolution imagery. *Remote Sensing Letters*, **5**, 73-82.
- Zhang, X. C., Kang, T. J., Wang, H. Y. ve Sun, Y.** (2010). Analysis on spatial structure of landuse change based on remote sensing and geographical information system. *International Journal of Applied Earth Observation and Geoinformation*, **12**, S145-S150.
- Zhang, Y. ve Mishra, R. K.** (2012). A Review and Comparison of Commercially Available Pan-Sharpening Techniques for High Resolution Satellite Image Fusion. *2012 IEEE International Geoscience and Remote Sensing Symposium (Igarss)*, 182-185.
- Zhou, W. Q., Huang, G. L., Troy, A. ve Cadenasso, M. L.** (2009). Object-based land cover classification of shaded areas in high spatial resolution imagery of urban areas: A comparison study. *Remote Sensing of Environment*, **113**, 1769-1777.
- Zhou, X. ve Dillon, T.** (1988). A heuristic-statistical feature selection criterion for inductive machine learning in the real world. In Proceedings of the IEEE International Conference on Systems, Man, and Cybernetics, **1**, 548-552.

**Url-1** <<http://www.commons.wikimedia.org>>, alındığı tarih: 01.06.2013

## **EKLER**

### **EK A: Optimum Parametre Seçimleri**

**EK A: Optimum Parametre Seçimleri****Çizelge A.1 :** Obje tabanlı sınıflandırmada DVM algoritması için belirlenen optimum parametre değerleri.

| Veri seti Boyutu | Veri Seti  | Düzenleme parametresi<br>(C) | Kernel genişliği<br>( $\gamma$ ) |
|------------------|------------|------------------------------|----------------------------------|
| 10 bant          | ChiSquare  | 1000                         | 0,05                             |
|                  | Fisher     | 750                          | 0,05                             |
|                  | GainRatio  | 5000                         | 0,03                             |
|                  | InfoGain   | 2000                         | 0,04                             |
|                  | NaiveBayes | 1000                         | 0,06                             |
|                  | OneR       | 5000                         | 0,05                             |
|                  | Pearson    | 1500                         | 0,08                             |
|                  | ProbSig    | 1500                         | 0,06                             |
|                  | ReliefF    | 500                          | 0,05                             |
|                  | RF         | 1000                         | 0,04                             |
|                  | DVM-ÖÖE    | 750                          | 0,09                             |
|                  | SymtUnc    | 5000                         | 0,05                             |
|                  | Ttest      | 5000                         | 0,05                             |
| 20 bant          | ChiSquare  | 1500                         | 0,05                             |
|                  | Fisher     | 2500                         | 0,05                             |
|                  | GainRatio  | 4500                         | 0,08                             |
|                  | InfoGain   | 5000                         | 0,04                             |
|                  | NaiveBayes | 3000                         | 0,06                             |
|                  | OneR       | 3500                         | 0,05                             |
|                  | Pearson    | 5000                         | 0,06                             |
|                  | ProbSig    | 3500                         | 0,05                             |
|                  | ReliefF    | 1500                         | 0,05                             |
|                  | RF         | 2000                         | 0,05                             |
|                  | DVM-ÖÖE    | 1000                         | 0,05                             |
|                  | SymtUnc    | 5000                         | 0,06                             |
|                  | Ttest      | 4000                         | 0,04                             |
| 30 bant          | ChiSquare  | 5000                         | 0,05                             |
|                  | Fisher     | 2000                         | 0,05                             |
|                  | GainRatio  | 5000                         | 0,04                             |
|                  | InfoGain   | 1500                         | 0,05                             |
|                  | NaiveBayes | 5000                         | 0,06                             |
|                  | OneR       | 2000                         | 0,05                             |
|                  | Pearson    | 2000                         | 0,05                             |
|                  | ProbSig    | 2000                         | 0,03                             |
|                  | ReliefF    | 5000                         | 0,08                             |
|                  | RF         | 2000                         | 0,07                             |
|                  | DVM-ÖÖE    | 500                          | 0,05                             |
|                  | SymtUnc    | 2000                         | 0,06                             |
|                  | Ttest      | 3500                         | 0,06                             |



**Çizelge A.1 (devam) :** Obje tabanlı sınıflandırmada DVM algoritması için belirlenen optimum parametre değerleri.

| Veri seti Boyutu | Veri Seti  | Düzenleme parametresi<br>(C) | Kernel genişliği<br>( $\gamma$ ) |
|------------------|------------|------------------------------|----------------------------------|
| 40 bant          | ChiSquare  | 500                          | 0,05                             |
|                  | Fisher     | 1500                         | 0,05                             |
|                  | GainRatio  | 5000                         | 0,03                             |
|                  | InfoGain   | 1500                         | 0,06                             |
|                  | NaiveBayes | 2000                         | 0,08                             |
|                  | OneR       | 5000                         | 0,05                             |
|                  | Pearson    | 1500                         | 0,05                             |
|                  | ProbSig    | 1000                         | 0,05                             |
|                  | ReliefF    | 750                          | 0,05                             |
|                  | RF         | 4000                         | 0,04                             |
|                  | DVM-ÖÖE    | 200                          | 0,04                             |
|                  | SymtUnc    | 2000                         | 0,06                             |
|                  | Ttest      | 2000                         | 0,05                             |
| 50 bant          | ChiSquare  | 750                          | 0,08                             |
|                  | Fisher     | 200                          | 0,06                             |
|                  | GainRatio  | 500                          | 0,06                             |
|                  | InfoGain   | 500                          | 0,03                             |
|                  | NaiveBayes | 500                          | 0,05                             |
|                  | OneR       | 200                          | 0,04                             |
|                  | Pearson    | 200                          | 0,05                             |
|                  | ProbSig    | 1500                         | 0,06                             |
|                  | ReliefF    | 200                          | 0,05                             |
|                  | RF         | 1000                         | 0,05                             |
|                  | DVM-ÖÖE    | 5000                         | 0,04                             |
|                  | SymtUnc    | 2000                         | 0,08                             |
|                  | Ttest      | 1500                         | 0,07                             |
| 75 bant          | ChiSquare  | 2000                         | 0,05                             |
|                  | Fisher     | 500                          | 0,05                             |
|                  | GainRatio  | 750                          | 0,05                             |
|                  | InfoGain   | 750                          | 0,05                             |
|                  | NaiveBayes | 750                          | 0,04                             |
|                  | OneR       | 750                          | 0,08                             |
|                  | Pearson    | 750                          | 0,07                             |
|                  | ProbSig    | 5000                         | 0,04                             |
|                  | ReliefF    | 750                          | 0,06                             |
|                  | RF         | 750                          | 0,05                             |
|                  | DVM-ÖÖE    | 200                          | 0,05                             |
|                  | SymtUnc    | 750                          | 0,08                             |
|                  | Ttest      | 500                          | 0,07                             |

**Çizelge A.1 (devam)** : Obje tabanlı sınıflandırmada DVM algoritması için belirlenen optimum parametre değerleri.

| Veri seti Boyutu | Veri Seti  | Düzenleme parametresi<br>(C) | Kernel genişliği<br>( $\gamma$ ) |
|------------------|------------|------------------------------|----------------------------------|
| 100 bant         | ChiSquare  | 200                          | 0,05                             |
|                  | Fisher     | 200                          | 0,05                             |
|                  | GainRatio  | 2000                         | 0,04                             |
|                  | InfoGain   | 500                          | 0,04                             |
|                  | NaiveBayes | 500                          | 0,06                             |
|                  | OneR       | 750                          | 0,05                             |
|                  | Pearson    | 200                          | 0,06                             |
|                  | ProbSig    | 500                          | 0,05                             |
|                  | ReliefF    | 1500                         | 0,05                             |
|                  | RF         | 500                          | 0,06                             |
|                  | DVM-ÖÖE    | 200                          | 0,05                             |
|                  | SymtUnc    | 1500                         | 0,08                             |
|                  | Ttest      | 750                          | 0,07                             |
| 150 bant         | ChiSquare  | 5000                         | 0,05                             |
|                  | Fisher     | 100                          | 0,05                             |
|                  | GainRatio  | 500                          | 0,03                             |
|                  | InfoGain   | 1000                         | 0,09                             |
|                  | NaiveBayes | 750                          | 0,05                             |
|                  | OneR       | 200                          | 0,05                             |
|                  | Pearson    | 750                          | 0,04                             |
|                  | ProbSig    | 100                          | 0,08                             |
|                  | ReliefF    | 500                          | 0,04                             |
|                  | RF         | 1000                         | 0,06                             |
|                  | DVM-ÖÖE    | 500                          | 0,05                             |
|                  | SymtUnc    | 750                          | 0,06                             |
|                  | Ttest      | 200                          | 0,03                             |
| 200 bant         | ChiSquare  | 1000                         | 0,05                             |
|                  | Fisher     | 200                          | 0,05                             |
|                  | GainRatio  | 750                          | 0,08                             |
|                  | InfoGain   | 100                          | 0,03                             |
|                  | NaiveBayes | 100                          | 0,06                             |
|                  | OneR       | 100                          | 0,05                             |
|                  | Pearson    | 750                          | 0,08                             |
|                  | ProbSig    | 750                          | 0,07                             |
|                  | ReliefF    | 750                          | 0,05                             |
|                  | RF         | 200                          | 0,04                             |
|                  | DVM-ÖÖE    | 100                          | 0,06                             |
|                  | SymtUnc    | 500                          | 0,07                             |
|                  | Ttest      | 200                          | 0,06                             |

**Çizelge A.2 :** Obje tabanlı sınıflandırmada HIZ, TRB ve RotOR algoritmaları için optimum iterasyon sayısı değerleri.

| Veri seti Boyutu | Veri Seti  | İterasyon Sayısı |           |                |
|------------------|------------|------------------|-----------|----------------|
|                  |            | Hızlandırma      | Torbalama | Rotasyon Orman |
| 10 bant          | ChiSquare  | 50               | 40        | 30             |
|                  | Fisher     | 90               | 40        | 70             |
|                  | GainRatio  | 30               | 40        | 60             |
|                  | InfoGain   | 60               | 20        | 100            |
|                  | NaiveBayes | 30               | 60        | 50             |
|                  | OneR       | 40               | 90        | 90             |
|                  | Pearson    | 90               | 40        | 10             |
|                  | ProbSig    | 20               | 50        | 40             |
|                  | ReliefF    | 50               | 60        | 10             |
|                  | RF         | 40               | 40        | 80             |
|                  | DVM-ÖÖE    | 60               | 50        | 10             |
|                  | SymtUnc    | 40               | 40        | 100            |
|                  | Ttest      | 30               | 10        | 30             |
| 20 bant          | ChiSquare  | 60               | 20        | 100            |
|                  | Fisher     | 40               | 20        | 20             |
|                  | GainRatio  | 80               | 50        | 60             |
|                  | InfoGain   | 50               | 20        | 70             |
|                  | NaiveBayes | 20               | 20        | 80             |
|                  | OneR       | 70               | 30        | 20             |
|                  | Pearson    | 60               | 80        | 40             |
|                  | ProbSig    | 90               | 50        | 20             |
|                  | ReliefF    | 20               | 30        | 80             |
|                  | RF         | 50               | 30        | 50             |
|                  | DVM-ÖÖE    | 90               | 50        | 50             |
|                  | SymtUnc    | 10               | 60        | 70             |
|                  | Ttest      | 60               | 20        | 30             |
| 30 bant          | ChiSquare  | 30               | 70        | 30             |
|                  | Fisher     | 10               | 50        | 60             |
|                  | GainRatio  | 50               | 20        | 30             |
|                  | InfoGain   | 40               | 50        | 100            |
|                  | NaiveBayes | 60               | 10        | 40             |
|                  | OneR       | 30               | 10        | 20             |
|                  | Pearson    | 20               | 60        | 70             |
|                  | ProbSig    | 30               | 10        | 50             |
|                  | ReliefF    | 90               | 70        | 20             |
|                  | RF         | 30               | 60        | 20             |
|                  | DVM-ÖÖE    | 70               | 50        | 30             |
|                  | SymtUnc    | 70               | 40        | 30             |
|                  | Ttest      | 30               | 20        | 50             |

**Çizelge A.2 (devam) :** Obje tabanlı sınıflandırmada HIZ, TRB ve RotOR algoritmaları için optimum iterasyon sayısı değerleri.

| Veri seti Boyutu | Veri Seti  | İterasyon Sayısı |           |                |
|------------------|------------|------------------|-----------|----------------|
|                  |            | Hızlandırma      | Torbalama | Rotasyon Orman |
| 40 bant          | ChiSquare  | 10               | 20        | 50             |
|                  | Fisher     | 20               | 20        | 80             |
|                  | GainRatio  | 80               | 10        | 90             |
|                  | InfoGain   | 70               | 10        | 30             |
|                  | NaiveBayes | 20               | 20        | 90             |
|                  | OneR       | 70               | 50        | 100            |
|                  | Pearson    | 20               | 20        | 40             |
|                  | ProbSig    | 30               | 10        | 70             |
|                  | ReliefF    | 30               | 30        | 60             |
|                  | RF         | 40               | 10        | 30             |
|                  | DVM-ÖÖE    | 50               | 50        | 70             |
|                  | SymtUnc    | 40               | 10        | 60             |
|                  | Ttest      | 60               | 30        | 50             |
| 50 bant          | ChiSquare  | 30               | 20        | 30             |
|                  | Fisher     | 100              | 10        | 90             |
|                  | GainRatio  | 100              | 20        | 100            |
|                  | InfoGain   | 100              | 10        | 40             |
|                  | NaiveBayes | 100              | 20        | 60             |
|                  | OneR       | 70               | 50        | 90             |
|                  | Pearson    | 60               | 50        | 30             |
|                  | ProbSig    | 40               | 10        | 40             |
|                  | ReliefF    | 30               | 100       | 100            |
|                  | RF         | 90               | 10        | 100            |
|                  | DVM-ÖÖE    | 30               | 60        | 60             |
|                  | SymtUnc    | 40               | 10        | 50             |
|                  | Ttest      | 70               | 30        | 20             |
| 75 bant          | ChiSquare  | 30               | 20        | 100            |
|                  | Fisher     | 60               | 30        | 30             |
|                  | GainRatio  | 50               | 10        | 60             |
|                  | InfoGain   | 50               | 10        | 90             |
|                  | NaiveBayes | 50               | 30        | 50             |
|                  | OneR       | 60               | 60        | 30             |
|                  | Pearson    | 80               | 70        | 90             |
|                  | ProbSig    | 30               | 10        | 80             |
|                  | ReliefF    | 80               | 100       | 60             |
|                  | RF         | 70               | 20        | 20             |
|                  | DVM-ÖÖE    | 50               | 90        | 100            |
|                  | SymtUnc    | 60               | 10        | 90             |
|                  | Ttest      | 30               | 20        | 80             |

**Çizelge A.2 (devam) : Obje tabanlı sınıflandırmada HIZ, TRB ve RotOR algoritmaları için optimum iterasyon sayısı değerleri.**

| Veri seti Boyutu | Veri Seti  | İterasyon Sayısı |           |                |
|------------------|------------|------------------|-----------|----------------|
|                  |            | Hızlandırma      | Torbalama | Rotasyon Orman |
| 100 bant         | ChiSquare  | 60               | 30        | 70             |
|                  | Fisher     | 60               | 60        | 40             |
|                  | GainRatio  | 80               | 80        | 60             |
|                  | InfoGain   | 100              | 20        | 100            |
|                  | NaiveBayes | 40               | 60        | 90             |
|                  | OneR       | 20               | 30        | 30             |
|                  | Pearson    | 40               | 60        | 20             |
|                  | ProbSig    | 20               | 20        | 80             |
|                  | ReliefF    | 60               | 60        | 80             |
|                  | RF         | 40               | 10        | 30             |
|                  | DVM-ÖÖE    | 10               | 30        | 40             |
|                  | SymtUnc    | 40               | 60        | 50             |
|                  | Ttest      | 100              | 30        | 90             |
| 150 bant         | ChiSquare  | 50               | 30        | 40             |
|                  | Fisher     | 90               | 30        | 80             |
|                  | GainRatio  | 70               | 80        | 30             |
|                  | InfoGain   | 40               | 30        | 70             |
|                  | NaiveBayes | 40               | 20        | 80             |
|                  | OneR       | 100              | 30        | 50             |
|                  | Pearson    | 30               | 40        | 30             |
|                  | ProbSig    | 50               | 20        | 50             |
|                  | ReliefF    | 40               | 60        | 60             |
|                  | RF         | 20               | 30        | 20             |
|                  | DVM-ÖÖE    | 90               | 90        | 40             |
|                  | SymtUnc    | 30               | 80        | 70             |
|                  | Ttest      | 20               | 10        | 100            |
| 200 bant         | ChiSquare  | 40               | 40        | 20             |
|                  | Fisher     | 40               | 40        | 20             |
|                  | GainRatio  | 40               | 40        | 30             |
|                  | InfoGain   | 20               | 20        | 100            |
|                  | NaiveBayes | 40               | 60        | 50             |
|                  | OneR       | 60               | 90        | 80             |
|                  | Pearson    | 50               | 40        | 50             |
|                  | ProbSig    | 40               | 50        | 70             |
|                  | ReliefF    | 40               | 60        | 90             |
|                  | RF         | 30               | 40        | 30             |
|                  | DVM-ÖÖE    | 40               | 50        | 80             |
|                  | SymtUnc    | 30               | 40        | 90             |
|                  | Ttest      | 90               | 10        | 90             |

**Çizelge A.3 :** Obje tabanlı sınıflandırmada ÇH algoritması için belirlenen optimum parametre değerleri.

| Veri seti Boyutu | Veri Seti  | İterasyon Sayısı | Alt komitelerin sayısı |
|------------------|------------|------------------|------------------------|
| 10 bant          | ChiSquare  | 70               | 3                      |
|                  | Fisher     | 10               | 4                      |
|                  | GainRatio  | 90               | 2                      |
|                  | InfoGain   | 30               | 3                      |
|                  | NaiveBayes | 20               | 3                      |
|                  | OneR       | 70               | 1                      |
|                  | Pearson    | 70               | 6                      |
|                  | ProbSig    | 20               | 4                      |
|                  | ReliefF    | 20               | 5                      |
|                  | RF         | 20               | 4                      |
|                  | DVM-ÖÖE    | 100              | 2                      |
|                  | SymtUnc    | 20               | 4                      |
|                  | Ttest      | 50               | 1                      |
| 20 bant          | ChiSquare  | 70               | 4                      |
|                  | Fisher     | 50               | 3                      |
|                  | GainRatio  | 40               | 3                      |
|                  | InfoGain   | 40               | 2                      |
|                  | NaiveBayes | 30               | 1                      |
|                  | OneR       | 70               | 1                      |
|                  | Pearson    | 60               | 4                      |
|                  | ProbSig    | 10               | 4                      |
|                  | ReliefF    | 50               | 4                      |
|                  | RF         | 30               | 2                      |
|                  | DVM-ÖÖE    | 90               | 2                      |
|                  | SymtUnc    | 40               | 1                      |
|                  | Ttest      | 50               | 2                      |
| 30 bant          | ChiSquare  | 40               | 2                      |
|                  | Fisher     | 50               | 1                      |
|                  | GainRatio  | 60               | 2                      |
|                  | InfoGain   | 90               | 6                      |
|                  | NaiveBayes | 90               | 2                      |
|                  | OneR       | 50               | 3                      |
|                  | Pearson    | 70               | 2                      |
|                  | ProbSig    | 60               | 4                      |
|                  | ReliefF    | 40               | 2                      |
|                  | RF         | 80               | 1                      |
|                  | DVM-ÖÖE    | 40               | 1                      |
|                  | SymtUnc    | 90               | 4                      |
|                  | Ttest      | 80               | 2                      |

**Çizelge A.3 (devam) :** Obje tabanlı sınıflandırmada ÇH algoritması için belirlenen optimum parametre değerleri.

| Veri seti Boyutu | Veri Seti  | İterasyon Sayısı | Alt komitelerin sayısı |
|------------------|------------|------------------|------------------------|
| 40 bant          | ChiSquare  | 70               | 1                      |
|                  | Fisher     | 50               | 3                      |
|                  | GainRatio  | 80               | 2                      |
|                  | InfoGain   | 90               | 6                      |
|                  | NaiveBayes | 60               | 4                      |
|                  | OneR       | 10               | 3                      |
|                  | Pearson    | 60               | 2                      |
|                  | ProbSig    | 60               | 1                      |
|                  | ReliefF    | 30               | 2                      |
|                  | RF         | 70               | 4                      |
|                  | DVM-ÖÖE    | 60               | 3                      |
|                  | SymtUnc    | 40               | 2                      |
|                  | Ttest      | 40               | 2                      |
| 50 bant          | ChiSquare  | 70               | 1                      |
|                  | Fisher     | 70               | 4                      |
|                  | GainRatio  | 20               | 2                      |
|                  | InfoGain   | 80               | 3                      |
|                  | NaiveBayes | 30               | 3                      |
|                  | OneR       | 50               | 2                      |
|                  | Pearson    | 30               | 2                      |
|                  | ProbSig    | 70               | 2                      |
|                  | ReliefF    | 90               | 2                      |
|                  | RF         | 90               | 3                      |
|                  | DVM-ÖÖE    | 40               | 2                      |
|                  | SymtUnc    | 60               | 1                      |
|                  | Ttest      | 100              | 2                      |
| 75 bant          | ChiSquare  | 70               | 1                      |
|                  | Fisher     | 60               | 3                      |
|                  | GainRatio  | 90               | 2                      |
|                  | InfoGain   | 100              | 2                      |
|                  | NaiveBayes | 40               | 1                      |
|                  | OneR       | 60               | 1                      |
|                  | Pearson    | 60               | 1                      |
|                  | ProbSig    | 80               | 1                      |
|                  | ReliefF    | 20               | 1                      |
|                  | RF         | 50               | 2                      |
|                  | DVM-ÖÖE    | 60               | 2                      |
|                  | SymtUnc    | 70               | 2                      |
|                  | Ttest      | 70               | 2                      |

**Çizelge A.3 (devam) :** Obje tabanlı sınıflandırmada ÇH algoritması için belirlenen optimum parametre değerleri.

| Veri seti Boyutu | Veri Seti  | İterasyon Sayısı | Alt komitelerin sayısı |
|------------------|------------|------------------|------------------------|
| 100 bant         | ChiSquare  | 50               | 3                      |
|                  | Fisher     | 100              | 2                      |
|                  | GainRatio  | 60               | 2                      |
|                  | InfoGain   | 60               | 3                      |
|                  | NaiveBayes | 70               | 1                      |
|                  | OneR       | 100              | 2                      |
|                  | Pearson    | 50               | 2                      |
|                  | ProbSig    | 60               | 1                      |
|                  | ReliefF    | 100              | 2                      |
|                  | RF         | 80               | 1                      |
|                  | DVM-ÖÖE    | 90               | 2                      |
|                  | SymtUnc    | 40               | 2                      |
|                  | Ttest      | 50               | 1                      |
| 150 bant         | ChiSquare  | 70               | 2                      |
|                  | Fisher     | 70               | 2                      |
|                  | GainRatio  | 80               | 1                      |
|                  | InfoGain   | 100              | 1                      |
|                  | NaiveBayes | 100              | 2                      |
|                  | OneR       | 40               | 2                      |
|                  | Pearson    | 30               | 2                      |
|                  | ProbSig    | 60               | 2                      |
|                  | ReliefF    | 80               | 1                      |
|                  | RF         | 100              | 3                      |
|                  | DVM-ÖÖE    | 50               | 2                      |
|                  | SymtUnc    | 90               | 3                      |
|                  | Ttest      | 30               | 2                      |
| 200 bant         | ChiSquare  | 50               | 3                      |
|                  | Fisher     | 100              | 2                      |
|                  | GainRatio  | 60               | 1                      |
|                  | InfoGain   | 50               | 3                      |
|                  | NaiveBayes | 60               | 3                      |
|                  | OneR       | 40               | 2                      |
|                  | Pearson    | 80               | 2                      |
|                  | ProbSig    | 40               | 1                      |
|                  | ReliefF    | 90               | 2                      |
|                  | RF         | 40               | 3                      |
|                  | DVM-ÖÖE    | 80               | 1                      |
|                  | SymtUnc    | 60               | 3                      |
|                  | Ttest      | 30               | 3                      |



**Çizelge A.4 :** Obje tabanlı sınıflandırmada RO algoritması için belirlenen optimum parametre değerleri.

| Veri seti Boyutu | Veri Seti  | Ağaç sayısı | Özellik sayısı |
|------------------|------------|-------------|----------------|
| 10 bant          | ChiSquare  | 30          | 3              |
|                  | Fisher     | 70          | 4              |
|                  | GainRatio  | 40          | 2              |
|                  | InfoGain   | 60          | 6              |
|                  | NaiveBayes | 90          | 8              |
|                  | OneR       | 40          | 6              |
|                  | Pearson    | 30          | 3              |
|                  | ProbSig    | 50          | 6              |
|                  | ReliefF    | 40          | 6              |
|                  | RF         | 20          | 5              |
|                  | DVM-ÖÖE    | 60          | 5              |
|                  | SymtUnc    | 40          | 3              |
|                  | Ttest      | 50          | 4              |
| 20 bant          | ChiSquare  | 30          | 2              |
|                  | Fisher     | 80          | 3              |
|                  | GainRatio  | 50          | 7              |
|                  | InfoGain   | 40          | 5              |
|                  | NaiveBayes | 70          | 4              |
|                  | OneR       | 50          | 3              |
|                  | Pearson    | 50          | 6              |
|                  | ProbSig    | 40          | 7              |
|                  | ReliefF    | 60          | 8              |
|                  | RF         | 100         | 1              |
|                  | DVM-ÖÖE    | 80          | 4              |
|                  | SymtUnc    | 100         | 4              |
|                  | Ttest      | 50          | 2              |
| 30 bant          | ChiSquare  | 50          | 7              |
|                  | Fisher     | 30          | 7              |
|                  | GainRatio  | 60          | 9              |
|                  | InfoGain   | 50          | 7              |
|                  | NaiveBayes | 100         | 1              |
|                  | OneR       | 50          | 3              |
|                  | Pearson    | 50          | 10             |
|                  | ProbSig    | 40          | 5              |
|                  | ReliefF    | 50          | 7              |
|                  | RF         | 30          | 6              |
|                  | DVM-ÖÖE    | 50          | 2              |
|                  | SymtUnc    | 30          | 2              |
|                  | Ttest      | 100         | 6              |

**Çizelge A.4 (devam) :** Obje tabanlı sınıflandırmada RO algoritması için belirlenen optimum parametre değerleri.


| Veri seti Boyutu | Veri Seti  | Ağaç sayısı | Özellik sayısı |
|------------------|------------|-------------|----------------|
| 40 bant          | ChiSquare  | 50          | 1              |
|                  | Fisher     | 80          | 8              |
|                  | GainRatio  | 50          | 5              |
|                  | InfoGain   | 90          | 4              |
|                  | NaiveBayes | 90          | 5              |
|                  | OneR       | 60          | 6              |
|                  | Pearson    | 40          | 5              |
|                  | ProbSig    | 30          | 7              |
|                  | ReliefF    | 70          | 10             |
|                  | RF         | 50          | 6              |
|                  | DVM-ÖÖE    | 70          | 1              |
|                  | SymtUnc    | 10          | 5              |
|                  | Ttest      | 90          | 4              |
| 50 bant          | ChiSquare  | 80          | 10             |
|                  | Fisher     | 90          | 7              |
|                  | GainRatio  | 90          | 10             |
|                  | InfoGain   | 70          | 7              |
|                  | NaiveBayes | 90          | 3              |
|                  | OneR       | 80          | 9              |
|                  | Pearson    | 50          | 4              |
|                  | ProbSig    | 70          | 9              |
|                  | ReliefF    | 90          | 3              |
|                  | RF         | 100         | 8              |
|                  | DVM-ÖÖE    | 40          | 5              |
|                  | SymtUnc    | 20          | 7              |
|                  | Ttest      | 50          | 8              |
| 75 bant          | ChiSquare  | 60          | 7              |
|                  | Fisher     | 30          | 7              |
|                  | GainRatio  | 20          | 10             |
|                  | InfoGain   | 20          | 6              |
|                  | NaiveBayes | 70          | 6              |
|                  | OneR       | 40          | 10             |
|                  | Pearson    | 70          | 8              |
|                  | ProbSig    | 60          | 8              |
|                  | ReliefF    | 90          | 9              |
|                  | RF         | 40          | 8              |
|                  | DVM-ÖÖE    | 40          | 7              |
|                  | SymtUnc    | 30          | 8              |
|                  | Ttest      | 60          | 5              |

**Çizelge A.4 (devam) :** Obje tabanlı sınıflandırmada RO algoritması için belirlenen optimum parametre değerleri.

| Veri seti Boyutu | Veri Seti  | Ağaç sayısı | Özellik sayısı |
|------------------|------------|-------------|----------------|
| 100 bant         | ChiSquare  | 50          | 6              |
|                  | Fisher     | 30          | 6              |
|                  | GainRatio  | 100         | 8              |
|                  | InfoGain   | 90          | 9              |
|                  | NaiveBayes | 30          | 4              |
|                  | OneR       | 30          | 6              |
|                  | Pearson    | 30          | 1              |
|                  | ProbSig    | 40          | 4              |
|                  | ReliefF    | 70          | 1              |
|                  | RF         | 40          | 8              |
|                  | DVM-ÖÖE    | 60          | 2              |
|                  | SymtUnc    | 70          | 4              |
|                  | Ttest      | 60          | 9              |
| 150 bant         | ChiSquare  | 80          | 1              |
|                  | Fisher     | 20          | 5              |
|                  | GainRatio  | 30          | 6              |
|                  | InfoGain   | 70          | 3              |
|                  | NaiveBayes | 100         | 4              |
|                  | OneR       | 100         | 2              |
|                  | Pearson    | 90          | 4              |
|                  | ProbSig    | 40          | 8              |
|                  | ReliefF    | 90          | 8              |
|                  | RF         | 80          | 1              |
|                  | DVM-ÖÖE    | 100         | 4              |
|                  | SymtUnc    | 50          | 10             |
|                  | Ttest      | 90          | 3              |
| 200 bant         | ChiSquare  | 90          | 1              |
|                  | Fisher     | 90          | 7              |
|                  | GainRatio  | 70          | 6              |
|                  | InfoGain   | 90          | 4              |
|                  | NaiveBayes | 90          | 6              |
|                  | OneR       | 60          | 10             |
|                  | Pearson    | 40          | 7              |
|                  | ProbSig    | 90          | 2              |
|                  | ReliefF    | 60          | 5              |
|                  | RF         | 90          | 4              |
|                  | DVM-ÖÖE    | 50          | 5              |
|                  | SymtUnc    | 30          | 7              |
|                  | Ttest      | 50          | 8              |



## ÖZGEÇMİŞ



**Ad Soyad:** İsmail ÇÖLKESEN

**Doğum Yeri ve Tarihi:** ANKARA/1981

**E-Posta:** icolkesen@gmail.com

**Lisans:** 2004, Karadeniz Teknik Üniversitesi, Mühendislik Mimarlık Fakültesi, Jeodezi ve Fotogrametri Mühendisliği Bölümü

**Yüksek Lisans:** 2009, Gebze Yüksek Teknoloji Enstitüsü, Jeodezi ve Fotogrametri Anabilim Dalı, Jeodezi ve Fotogrametri Mühendiliği

## YAYIN LİSTESİ

### Uluslararası Makale (SCI)

- Kavzoglu, T., Sahin, E.K., **Colkesen, I.**, 2014. An assessment of multivariate and bivariate approaches in landslide susceptibility mapping: a case study of Duzkoy district, *Natural Hazard*, DOI 10.1007/s11069-014-1506-8.
- Kavzoglu, T., Sahin, E.K., **Colkesen, I.**, 2014. Landslide susceptibility mapping using GIS-based multi-criteria decision analysis, support vector machines, and logistic regression, *Landslides*, 11(3), 425-439.
- Kavzoglu, T., **Colkesen, I.**, 2013. An assessment of effectiveness of rotation forest ensemble for land use and land cover mapping, *International Journal of Remote Sensing*, 34(12), 4224-4241.
- Kavzoglu, T., **Colkesen, I.**, 2011. Assessment of environmental change and land degradation using time series of remote sensing images, *Fresenius Environmental Bulletin*, 20(1a), 274-281.
- Kavzoglu, T., **Colkesen, I.**, 2011. Entropic distance based K-star algorithm for remote sensing image classification, *Fresenius Environmental Bulletin*, 20(5), 1200-1207.
- Ergun, B., Kavzoglu, T., **Colkesen, I.**, Sahin, C., 2010. Data filtering with support vector machines in geometric camera calibration, *Optics Express*, 18(3), 1927-1936, (2010).
- Kavzoglu, T., Colkesen, I., 2009. A kernel functions analysis for support vector machines for land cover classification. *International Journal of Applied Earth Observation and Geoinformation*, 11(5), 352-359.
- Sesli, F.A., Karşlı, F., **Colkesen, I.**, Akyol, N., 2009. Monitoring the changing position of coastlines using aerial and satellite image data: an

example from the easterncoast of Trabzon, Turkey, *Environmental Monitoring and Assesment*, 153(1-4), 391-403.

### Ulusal Makale

- Kavzoğlu, T., **Çölkesen, İ.**, 2010. Karar ağaçları ile uydu görüntülerinin sınıflandırılması: Kocaeli örneği, *Harita Teknolojileri Elektronik Dergisi*,2(1),36-45.
- Kavzoğlu, T., **Çölkesen, İ.**, 2010. Destek vektör makineleri ile uydu görüntülerinin sınıflandırılmasında kernel fonksiyonlarının etkilerinin incelenmesi, *Harita Dergisi*,144(7),73-82.
- Kavzoğlu, T., Şahin E.K., **Çölkesen, İ.**, 2012. Heyelan duyarlılığının incelenmesinde regresyon ağaçlarının kullanımı: Trabzon örneği, *Harita Dergisi*, 147(3),21-33.

### Uluslararası Bildiri

- Kavzoglu, T., **Colkesen, I.**, 2012. The Effects of Training Set Size for the Performance of Support Vector Machines and Decision Trees, *Proceedings of 10th International Symposium on Spatial Accuracy Assessment in Natural Resources and Environmental Sciences (ACCURACY2012)*, 10-13 July, Florianópolis, SC, Brazil,127-132.
- Yildiz, M., Kavzoglu, T., **Colkesen, I.**, Sahin, E.K., 2012. An Assessment of the Effectiveness of Segmentation Methods on Classification Performance, *Proceedings of 10th International Symposium on Spatial Accuracy Assessment in Natural Resources and Environmental Sciences (ACCURACY2012)*, 10-13 July, Florianópolis, SC, Brazil,133-138.

### Ulusal Bildiri

- Kavzoglu,T., Şahin, E.K., **Çölkesen, İ.**, 2014. Heyelan Duyarlılık Analizinde Ki-Kare Testine Dayalı Faktör Seçimi, 5. *Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu (UZALCBS'2014)*, 14-17 Ekim 2014, İstanbul.
- Kavzoğlu, T., **Çölkesen, İ.**, Şahin, E.K., 2013. Multispektral Uydu Görüntüleri İçin En Uygun Bant Seçiminin Sınıflandırma Doğruluğuna Etkilerinin İncelenmesi, *Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği VII. Sempozyumu (TUFUAB2013)*, 23–25 Mayıs 2013, Trabzon.
- Kavzoğlu, T., **Çölkesen, İ.**, 2013. Arazi Örtüsü Haritalarının Üretilmesinde Yeryüzü Özelliklerinin Sınıflandırma Doğruluğuna Etkilerinin İncelenmesi: Trabzon Örneği, *Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği VII. Sempozyumu (TUFUAB2013)*, 23–25 Mayıs 2013, Trabzon.
- Kavzoğlu, T., **Çölkesen, İ.**, Şahin, E.K., 2012. Heyelan Duyarlılık Haritasının Üretilmesinde Kullanılan Faktörlerin Etkilerinin Araştırılması:Düzköy Örneği, 4. *Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu (UZALCBS'2012)*, 16-19 Ekim 2012, Zonguldak.
- Kavzoğlu, T., **Çölkesen, İ.**, 2011. Uzaktan Algılama Teknolojileri ve Uygulama Alanları, *Türkiye’de Sürdürülebilir Arazi Yönetimi Çalıştayı*, 26-27 Mayıs 2011, Okan Üniversitesi,İstanbul.
- Kavzoğlu, T., **Çölkesen, İ.**, 2011. Örnek Tabanlı K-Star Algoritması İle Uzaktan Algılanmış Görüntülerin Sınıflandırılması, *Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği VI. Sempozyumu (TUFUAB2011)*, 23–26 Şubat 2011, Antalya.

- Kavzoğlu, T., Şahin, E.K., **Çölkesen, İ.**, 2010. CBS Tabanlı Çok Kriterli Karar Analizi Yöntemiyle Heyelan Duyarlılık Haritasının Üretilmesi: Trabzon İli Örneği, 3. *Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu (UZALCBS'2010)*, 11-13 Ekim 2010, Gebze, s.486-495.
- Kavzoğlu, T., **Çölkesen, İ.**, 2010. Yapay Bağışıklık Tabanlı sınıflandırma Yöntemiyle Uzaktan Algılanmış Görüntülerin Sınıflandırılması, 3. *Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu (UZALCBS'2010)*, 11-13 Ekim 2010, Gebze, s.447-454.
- **Çölkesen, İ.**, Kavzoğlu, T., 2010. Farklı Boyutta Eğitim Örnekleri İçin Destek Vektör Makinelerinin Sınıflandırma Performansının Analizi, 3. *Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu (UZALCBS'2010)*, 11-13 Ekim 2010, Gebze, s.161-170.
- **Çölkesen, İ.**, Kavzoğlu, T., 2009. İyileştirilmiş Karar Ağaçları ile Uydu Görüntülerinin Sınıflandırılması, *TMMOB Harita ve Kadastro Mühendisleri Odası 12. Türkiye Harita Bilimsel ve Teknik Kurultayı*, 11-15 Mayıs 2009, Ankara.
- **Çölkesen, İ.**, Kavzoğlu, T., 2008. Destek Vektör Makineleri Kullanarak Arazi Örtüsünün Sınıflandırılması: Gebze Örneği, 2. *Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu (UZALCBS'2008)*, 13-15 Ekim 2008, Kayseri, 36-46.

#### TEZDEN TÜRETİLEN YAYINLAR VE SUNUMLAR

- **Çölkesen, İ.**, Yomralıoğlu T., 2014. Arazi Örtüsü ve Kullanımının Haritalanmasında WorldView-2 Uydu Görüntüsü ve Yardımcı Verilerin Kullanımı, *Harita Dergisi*, 152(2), 12-24.
- **Çölkesen, İ.**, Yomralıoğlu T., Kavzoğlu, T., 2014. Rotasyon Orman Algoritması İle Yüksek Çözünürlüklü Multispektral Uydu Görüntülerinin Sınıflandırılması, 5. *Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu (UZALCBS'2014)*, 14-17 Ekim 2014, İstanbul.