

**UZAKTAN ALGILAMA AMACIYLA
KULLANILACAK İSTATİSTİKSEL
ÖĞRENME TABANLI MODİFİYE BİR
SINIFLANDIRICI GELİŞTİRİLMESİ**

Emre MOLA

Doktora Tezi

Uzaktan Algılama ve Coğrafi Bilgi Sistemleri

Anabilim Dalı

Mart 2015

JÜRİ VE ENSTİTÜ ONAYI

Emre Mola'nın "Uzaktan Algılama Amacıyla Kullanılacak İstatistiksel Öğrenme Tabanlı Modifiye Bir Sınıflandırıcı Geliştirilmesi" başlıklı Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Anabilim Dalındaki, Doktora Tezi 30.01.2015 tarihinde aşağıdaki jüri tarafından Anadolu Üniversitesi Lisansüstü Eğitim ve Sınav Yönetmeliği'nin ilgili maddeleri uyarınca değerlendirilerek kabul edilmiştir.

	Adı Soyadı	İmza
Üye (Tez Danışmanı)	: Prof.Dr. Alper ÇABUK
Üye	: Prof.Dr. Şükran ŞAHİN
Üye	: Prof.Dr. Semra Günay AKTAŞ
Üye	: Doç.Dr. Hüseyin POLAT
Üye	: Doç.Dr. Yeliz Mert KANTAR

Anadolu Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulu'nun.....tarih ve.....sayılı kararıyla onaylanmıştır.

Enstitü Müdürü

ÖZET

Doktora Tezi

UZAKTAN ALGILAMA AMACIYLA KULLANILACAK İSTATİSTİKSEL ÖĞRENME TABANLI MODİFİYE BİR SINIFLANDIRICI GELİŞTİRİLMESİ

Emre MOLA

Anadolu Üniversitesi

Fen Bilimleri Enstitüsü

Uzaktan Algılama ve Coğrafi Bilgi Sistemleri

Anabilim Dalı

Danışman: Prof. Dr. Alper Çabuk

2015, 239 sayfa

Öğrenme bilimi; istatistik, veri madenciliği, yapay zeka, mühendislik ve diğer disiplin alanları ile kesişen alanlarda anahtar bir rol oynar. Bilimin, finansın ve endüstrinin bir çok alanında etkili olarak kullanılan istatistiksel öğrenme alanında etkili analiz tekniklerinden birisi olan EM algoritması zor olan en çok olabilirlik problemlerini basitleştirmek için popüler bir araçtır. İlk tahmin değerlerine duyarlılık, yerel minimum yakınsama, hızlı yakınsama ve de varyans kovaryans matrislerinin tekil olması gibi durumlar, EM algoritmasının parametre tahminlerini yapamaması ya da doğru yapamamasına yol açan eksikliklerdir.

Bu tezde EM algoritmasının teorik yapısı incelenerek, bu doğrultuda geliştirilen matlab kodu ile çeşitli özelliklerdeki uzaktan algılama verilerindeki sınıflara ait, parametrelerin tahmin edilmesi ve elde edilen parametre tahminleri yardımıyla görüntü sınıflandırması gerçekleştirilmiştir. Bazı durumlarda varyans kovaryans matris ya da matrislerinin tekillik tuzağına yakalandığı gözlemlenmiş, buna karşın EM algoritması modifiye edilerek, tekillik tuzağından kurtulması sağlanarak görüntü sınıflandırmaları başarı ile tamamlanmıştır.

Son olarak ilgili veriler için uzaktan algılamada bilinen bazı klasik sınıflandırıcılar ile modifiyesiz ve modifiyeli EM algoritması yardımı ile elde edilen görüntü sınıflama sonuçları karşılaştırılmış ve EM algoritması yardımı ile elde edilen modifiyeli ve modifiyesiz görüntü sınıflandırma sonuçlarının daha güvenilir olduğu görülmüştür.

Bu tezin temel amacı, ön bilgilendirmesiz ve ön bilgilendirmeli uzaklık esaslı ve olasılık dağılımı kullanmayan sınıflandırıcılara göre daha güvenilir sonuçlara ulaşmayı sağlayacak, istatistiksel öğrenme temelli yeni modifiye sınıflandırıcı geliştirmek olup; bu tezde, yukarıda bahsi geçen sorunların çözümlerini sağlayacak algoritmalar üzerinde çalışılmıştır.

Anahtar Kelimeler: Uzaktan Algılama, İstatistiksel Öğrenme, EM Algoritması, Modifiye EM Algoritması, Görüntü Sınıflandırması

ABSTRACT

PhD Dissertation

DEVELOPING A STATISTICAL LEARNING BASED MODIFIED CLASSIFIER FOR REMOTE SENSING PURPOSES

Emre MOLA

Anadolu University

Graduate School of Sciences

Remote Sensing and Geographical Information Systems Department

Supervisor :Prof.Dr. Alper Çabuk

2015, 239 pages

The science of learning plays a key role in the fields of statistics, data mining and artificial intelligence, intersecting areas of engineering and other disciplines. EM algorithm is an effective analysis technique in the field of statistical learning, a type of learning which is effectively used in many fields of science, finance and industry. It is also a popular tool for simplifying difficult maximum likelihood problems. The situations such as sensitivity to initial estimation values, local minima problem, faster convergence, and singularity of variance covariance matrices are certain problem leading to the consequences that EM algorithm cannot make parameter estimates or make inaccurate ones.

In this dissertation, theoretical structure of EM algorithm was examined and a matlab code was developed accordingly. Later, this code was used to make parameter estimates for various classes available in remote sensing data and image classification field with the help of these parameter estimates. It was observed that variance covariance matrix or matrices had singularity trap problems; however, image classifications were successfully completed after EM algorithm was modified to solve these singularity trap problems.

Finally, image classification results obtained by using several classical classifiers available in the field of remote sensing were compared with those obtained through unmodified and modified EM algorithm. It was observed that image classifications obtained through unmodified and modified EM algorithm were more reliable. The main objective of this dissertation is to develop a new statistical learning based modified classifier that will provide more reliable results than supervised and unsupervised and distance based classifiers that do not use probability distribution. It also deals with algorithms that will provide solutions to the problems mentioned above.

Keywords : Remote Sensing, Statistical Learning, EM Algorithm, Modified EM Algorithm, Image Classification

TEŞEKKÜR

Doktora çalışmam esnasında desteklerini gördüğüm aileme, tez çalışması sırasında verdiği taktiklerden ve olumlu eleştiriler ile böyle bir çalışmanın ortaya çıkmasına katkıları bulunan değerli danışman hocam Prof. Dr. Alper Çabuk'a, Tez izleme komitemde bulunan Prof.Dr. Şükran Şahin'e değerli olumlu eleştirileri ile bana karşı sergilemiş olduğu pozitif yaklaşım için, Doç.Dr. Hüseyin Polat'a değerli yönlendirmeleri ve örnek olduğu çalışkanlık ile değerli olumlu eleştirileri için, Prof.Dr. Semra Günay Aktaş'a çalışmamın geneli ve coğrafi konularında yapmış olduğu önemli olumlu eleştirileri ile göstermiş olduğu pozitif yaklaşım ve destekleri ve örnek olduğu çalışkanlık için, Doç Dr. Yeliz Mert Kantar'a istatistiksel konularda yapmış olduğu değerli eleştiriler ile sergilemiş olduğu pozitif yaklaşım ve destekleri için, Anadolu Üniversitesi Yer ve Uzay Bilimleri Enstitüsündeki ve Havacılık ve Uzay Fakültesindeki arkadaşlarıma, desteklerini gördüğüm akrabalarıma, teşekkür ederim.

Emre Mola

Mart 2015

İÇİNDEKİLER

Sayfa

ÖZET.....	i
ABSTRACT.....	ii
TEŞEKKÜR.....	iii
İÇİNDEKİLER.....	iv
ŞEKİLLER DİZİNİ.....	viii
ÇİZELGELER DİZİNİ.....	xiv
SİMGELER ve KISALTMALAR DİZİNİ.....	xv

1.GİRİŞ	1
2. KURAMSAL TEMELLER	5
2.1. Uzaktan Algılamada Temel Kavramlar.....	5
2.1.1. Uzaktan Algılamanın Kullanım Alanları.....	10
2.1.2. Uzaktan Algılama Prensipleri.....	14
2.1.3. Elektromagnetik Işınım.....	14
2.1.4. Elektromagnetik Spektrum.....	16
2.1.5. Işınım Kanunları	18
2.1.6. Elektromanyetik Işınımın Atmosfer ile Etkileşimi.....	22
2.1.7. Elektromanyetik Işınımın Yüzey ile Etkileşimi.....	24
2.1.8. Spektral İmza.....	27
2.1.9. Dijital Görüntü Kavramı ve Piksel.....	30
2.1.10. Algılayıcılar.....	32
2.1.11. Uzaktan Algılamada Çözünürlük Kavramı.....	44
2.1.11.1. Spektral Çözünürlük	44
2.1.11.2. Mekansal Çözünürlük	46
2.1.11.3. Radyometrik Çözünürlük	48

2.1.11.4. Zamansal Çözünürlük	49
2.2 . İstatistiksel Öğrenme Kavramı.....	50
2.2.1. İstatistiksel Öğrenmenin Kullanım Alanları.....	51
2.2.1.1 Uzaktan Algılama	56
2.2.1.2 Veri Madenciliği	60
2.2.1.3 Yapay Zeka	61
2.2.1.4. Bioinformatik	62
2.2.1.5. Diğer Alanlar.....	64
2.2.2. İstatistiksel Öğrenme Tabanlı Olarak Kullanılan Bazı Güçlü Sınıflandırıcılar, Algoritmalar ve Teorik Açıklamaları.....	66
2.2.2.1. En Çok Olabilirlik Kestiricisi ve Sınıflandırması	67
2.2.2.2. Bayes Çıkarımı, Kuralı, Risk, Kestirim ve Sınıflandırıcısı.....	72
2.3. EM Algoritması.....	86
2.3.1. İki Bileşenli Karma Model	89
2.3.2. Genel EM Algoritması	94
2.3.3. Bir Maksimizasyon-Maksimizasyon Yöntemi Olarak EM.....	96
3. LİTERATÜR ÖZETİ	98
4. MATERYAL-YÖNTEM	107
4.1. Materyal.....	108
4.2. Yöntem.....	109
4.2.1. EM Algoritmasının İki Bileşenli Gauss Dağılımı için Uygulanması.....	110
4.2.2. EM Algoritmasının İki Bileşenli Uzaktan Algılama Verisine Uygulanması.....	114
4.2.3. EM Algoritmasının Üç Bantlı ve İki Bileşenli Uzaktan Algılama Verisine Uygulanması.....	119
4.2.4. EM Algoritmasının Üç Bantlı ve Üç Bileşenli Uzaktan Algılama Verisine Uygulanması.....	125

4.2.5. EM Algoritmasının Üç Bantlı ve Dört Bileşenli Uzaktan Algılama Verisine Uygulanması.....	134
4.2.6. EM Algoritmasının Üç Bantlı ve Beş Bileşenli Uzaktan Algılama Verisine Uygulanması.....	139
4.2.7. Modifiye EM Algoritmasının Üç Bantlı ve 15 Bileşenli Uzaktan Algılama Verisine Uygulanması.....	143
4.2.8. Modifiye EM Algoritmasının Satürn Gezegeni Etrafındaki Halkalara Ait Uzaktan Algılama Verisine Uygulanması.....	153
4.2.9. EM Algoritmasının Jüpiter Gezegeni Atmosferi Uzaktan Algılama Verisine Uygulanması.....	160
4.2.10. EM Algoritması Yardımı ile Yapılan Sınıflandırma Sonuçlarının Klasik Sınıflandırıcı Sonuçları ile Karşılaştırılması.....	169
5. ARAŞTIRMA BULGULARI	171
5.1. EM Algoritmasının İki Bileşenli Gauss Dağılımı için Uygulanması.....	171
5.2. EM Algoritmasının İki Bileşenli Uzaktan Algılama Verisine Uygulanması.....	174
5.3. EM Algoritmasının Üç Bantlı ve İki Bileşenli Uzaktan Algılama Verisine Uygulanması.....	177
5.4. EM Algoritmasının Üç Bantlı ve Üç Bileşenli Uzaktan Algılama Verisine Uygulanması.....	181
5.5. EM Algoritmasının Üç Bantlı ve Dört Bileşenli Uzaktan Algılama Verisine Uygulanması.....	186
5.6. EM Algoritmasının Üç Bantlı ve Beş Bileşenli Uzaktan Algılama Verisine Uygulanması.....	189
5.7. Modifiye EM Algoritmasının Üç Bantlı ve 15 Bileşenli Uzaktan Algılama Verisine Uygulanması.....	195
5.8. Modifiye EM Algoritmasının Satürn Gezegeni Etrafındaki Halkalara Ait Uzaktan Algılama Verisine Uygulanması.....	201

5.9. EM Algoritmasının Jüpiter Gezegeni Atmosferi Uzaktan Algılama Verisine Uygulanması.....	212
6. ARAŞTIRMA SONUÇLARI	222
6.1. Üç Bant ve İki Bileşenli Uzaktan Algılama Verisine Bağlı Sonuçlar	222
6.2. Üç Bant ve Üç Bileşenli Uzaktan Algılama Verisine Bağlı Sonuçlar	223
6.3. Üç Bant ve Dört Bileşenli Uzaktan Algılama Verisine Bağlı Sonuçlar	224
6.4. Üç Bant ve Beş Bileşenli Uzaktan Algılama Verisine Bağlı Sonuçlar	225
6.5. Üç Bant ve 15 Bileşenli Uzaktan Algılama Verisine Bağlı Sonuçlar	226
6.6. Satürn Halkaları Uzaktan Algılama Verisine Bağlı Sonuçlar	227
6.7. Jüpiter Atmosferi Uzaktan Algılama Verisine Bağlı Sonuçlar	228
7. TARTIŞMA VE ÖNERİLER	230
KAYNAKLAR	234

ŞEKİLLER DİZİNİ

2.1. Uzaktan algılanmış bir tarla görüntüsü.....	10
2.2. Spektral sinyal.....	15
2.3. Farklı dalga boylarında elektromanyetik ışınım.....	15
2.4. Elektromanyetik Spektrum.....	17
2.5. “Boulevard du Temple, Paris”.....	18
2.6. Wien'nin yerdeğiştirme kanunu.....	21
2.7. Elektromanyetik spektrum boyunca atmosferik pencere dağılımı.....	24
2.8. Aynaya özgü yansıtma (a) dağınık yansıma (b).....	25
2.9. Ters kare yasası ve Lambert'in kosünüs yasası.....	26
2.10. İletim.....	27
2.11. Işınım ve madde arasındaki etkileşim.....	27
2.12. Toprak ve bitki örtüsünün spektral imzaları.....	28
2.13. Farklı nemlilik içeriklerine göre bitki örtüsü spektral imzalarının çeşitlilikleri.....	29
2.14. Farklı nemlilik içeriklerine göre siltli toprak spektral imzalarının çeşitlilikleri.....	29
2.15. Çoklu spektral pikseller.....	31
2.16. Algılayıcılara genel bakış.....	34
2.17. 17 km'ye 20 km'lik bir alanda Landsat 5 TM sahte renk bileşimi.....	35
2.18. Yer altında kömür yangınından etkilenen bir kömür madeni alanının termal görüntüsü.....	35
2.19. Hollanda, Sint Pietersberg'de bulunan açık maden ocağının sayısal yüzey modelinin resimli gösterimi.....	36
2.20. ERS-1 SAR görüntüsünün Kalimantan'da Mahakam deltası.....	37
2.21. Lazer altimetreler ve uzay bağlantılı radardan belirlenen deniz seviyesinin yüksekliği.....	38
2.22. Batı Hint okyanusunda, deniz tabanı kabartması.....	39
2.23. Üç farklı mekansal çözünürlükteki görüntülerin arasındaki karşılaştırma.....	47
2.24. Parlaklık değerleri.....	49
2.25. Landsat TM-Band 2, dört tip çözünürlük, kaynak EOSAT.....	50

2.26. Prostat kanseri verilerin saçılım matrisi.....	54
2.27 Birleşik Devletler posta zarflarından el yazması rakam örnekleri.....	55
2.28 DNA mikroçip verileri.....	58
2.29. Birlikte fakat tutarlı (agglomerative) kümeleme ile dağıtan (divisive) kümeleme metotlarının arasındaki farklılığı gösteren şematik betimleme.....	65
2.30. En çok olabilirlik sınıflandırması.....	71
2.31. Karma örnek.....	89
2.32. EM Algoritması: Yineleme sayısının bir fonksiyonu gibi gözlemlenmiş veri log-olabilirlik.....	93
2.33. EM algoritmasının maksimizasyon-maksimizasyon görünümü.....	97
4.1. NASA'nın sayfasından Dukono civarı uzaktan algılama verisi.....	114
4.2. Uzaktan algılanmış Dukono bölgesinden alınmış küçük iki bileşenli örneklem görüntüsü.....	115
4.3. Landsat 8 Eskişehir civarı 7, 4 ve 3 bant kombinasyonlu görüntüsü.....	119
4.4. Landsat 8 Eskişehir civarı 7, 4 ve 3 bant kombinasyonlu seçilen baraj göleti görüntüsü.....	120
4.5. Landsat 8 Eskişehir civarı 7, 4 ve 3 bant kombinasyonlu seçilen baraj göleti görüntüsü.....	121
4.6. Landsat 8 Eskişehir civarı 7, 4 ve 3 bant kombinasyonlu seçilen Porsuk baraj göletinin bir kısmının görüntüsü.....	122
4.7. Seçilen kısmın büyütülmüş hali.....	123
4.8. Landsat 8 Eskişehir civarı 7, 4 ve 3 bant kombinasyonlu görüntüsü.....	127
4.9. Landsat 8 Eskişehir civarı 7, 4 ve 3 bant kombinasyonlu görüntüsü büyütülmüş hali.....	128
4.10. Landsat 8 Eskişehir civarı 7, 4 ve 3 bant kombinasyonlu görüntüsü büyütülmüş hali.....	129
4.11. Seçilen alanın üst köşesi.....	130
4.12. Seçilen alanın alt köşesi.....	131
4.13. Sınıflandırılması yapılacak alanın büyütülmüş hali.....	131
4.14. Sınıflandırılması yapılacak alanın büyütülmüş hali.....	134
4.15. Sınıflandırılması yapılacak alanın büyütülmüş hali.....	135

4.16. Sınıflandırılması yapılacak alanın büyütülmüş hali.....	136
4.17. Sınıflandırılması yapılacak alanın büyütülmüş hali.....	136
4.18. Sınıflandırılması yapılacak uydu verisi.....	140
4.19. Sınıflandırılması yapılacak uydu verisinin büyütülmüş hali.....	140
4.20. Sınıflandırılması yapılacak Landsat 8 Eskişehir civarı 7, 4 ve 3 bant kombinasyonlu Porsuk baraj göleti uydu verisi.....	144
4.21. Sınıflandırılması yapılacak Landsat 8 Eskişehir civarı 7, 4 ve 3 bant kombinasyonlu Porsuk baraj göleti uydu verisinin daha büyük hali.....	145
4.22. Sınıflandırılması yapılacak uydu verisi.....	146
4.23. Voyager-2'den elde edilmiş Satürn gezegeninin halkaları uzaktan algılama verisi.....	153
4.24. Jüpiter gezegeni.....	161
4.25. Jüpiter'in büyük kırmızı beneği	161
4.26. Jüpiter'in büyük kırmızı beneği verisinden EM algoritmasına uygulanacak olan kısım.....	162
5.1. EM Algoritmasını başlatan ilk değerlerin girilmesi	171
5.2. İlk değerlerin girilmesinden sonra EM algoritmasının çalışması ve yinelemeler esnasında anlık ekran görüntüsü.....	171
5.3. EM algoritmasında yakınsamanın başlaması esnasındaki anlık ekran görüntüsü.....	172
5.4. EM algoritması tamamlandıktan sonraki özet durum.....	172
5.5. EM Algoritmasında yakınsama sürecine kadar olan yinemelerin grafiksel gösterimi.....	173
5.6. EM algoritması süreci tamamlandıktan sonra birinci bileşene ait dağılım grafiği.....	173
5.7. EM algoritması süreci tamamlandıktan sonra ikinci bileşene ait dağılım grafiği.....	173
5.8. EM algoritması tamamlandıktan oluşan iki bileşenli karma dağılım modelinin grafiği.....	174
5.9. Uzaktan algılanmış Dukono civarı verisi için EM algoritmasını başlatan ilk tahmin değerlerinin girilmesi.....	175

5.10. Uzaktan algılanmış Dukono civarı verisine ait ilk değerlerin girilmesinden sonra EM algoritmasının çalışması ve yinelemeler.....	175
5.11. Uzaktan algılanmış Dukono civarı verisi için iki karma modeline ait ağırlıklı olasılıkların iterasyon sonucunda yakınsama durumu.....	175
5.12. Dukono civarı verisi için birinci karma modele yani kara sınıfına ait olasılık yoğunluk fonksiyonu eğrisi.....	176
5.13. Dukono civarı verisi için ikinci karma modele yani deniz sınıfına ait olasılık yoğunluk fonksiyonu eğrisi.....	176
5.14. EM algoritması tamamlandıktan oluşan Dukono civarı verisi için kara ve denize ait karma modelin olasılık yoğunluk fonksiyonun grafiği....	176
5.15. Dukono civarı verisi için EM algoritması ile elde edilen karma modeli parametre tahminleri ile elde edilen sınıflandırılmış görüntü.....	177
5.16. Dukono civarı verisi (a) için EM algoritması yardımı ile sınıflandırmış Görüntü (b) ve orjinal görüntü (a).....	177
5.17. Üç bant ve iki sınıf için EM algoritması sonucu elde edilen parametre tahminleri ve karma model yardımı ile gerçekleştirilmiş olan sınıflandırma işlemi sonucunun görüntüsü.....	179
5.18. Üç bant ve iki sınıf için Isodata sınıflandırma sonucu görüntüsü.....	179
5.19. Üç bant ve iki sınıf için yapılan ön bilgilendirme	180
5.20. Üç bant ve iki sınıf için yapılan ön bilgilendirme değerleri.....	180
5.21. Üç bant ve iki sınıf için en kısa uzaklık sınıflandırma sonucu görüntüsü.....	180
5.22. Üç bant ve iki sınıf için Mahalanobis uzaklık sınıflandırma sonucu görüntüsü.....	181
5.23. Üç bant ve üç sınıf için EM algoritması sonucu elde edilen parametre tahminleri ve karma model yardımı ile gerçekleştirilmiş olan sınıflandırma işlemi sonucunun görüntüsü.....	183
5.24. Üç bant ve üç sınıf için Isodata sınıflandırma sonucu gri ton görüntüsü.....	183
5.25. Üç bant ve üç sınıf için Isodata sınıflandırma sonucu renkli görüntüsü....	184
5.26. Üç bant ve üç sınıf için yapılan ön bilgilendirme.....	184
5.27. Üç bant ve üç sınıf için en kısa uzaklık sınıflandırma sonucu görüntüsü.....	185

5.28. Üç bant ve üç sınıf için Mahalanobis uzaklık sınıflandırma sonucu görüntüsü.....	185
5.29. Üç bant ve dört sınıf tahmini için EM algoritması sonucu elde edilen parametre tahminleri ve karma model yardımı ile gerçekleştirilmiş olan sınıflandırma analizi sonucunun görüntüsü	187
5.30. Üç bant ve dört sınıf için Isodata kümeleme analizi sonucu gri ton görüntüsü	188
5.31. Üç bant ve dört sınıf tahmini için Isodata kümeleme analizi sonucu görüntüsü	188
5.32. Üç bant ve dört sınıf tahmini için yapılan ön bilgilendirme.....	188
5.33. Üç bant ve dört sınıf tahmini için en kısa uzaklık sınıflandırma sonucu görüntüsü.....	189
5.34. Üç bant ve dört sınıf tahmini için Mahalanobis uzaklık sınıflandırma sonucu görüntüsü.....	189
5.35. Üç bant ve beş sınıf tahmini için EM algoritması sonucu elde edilen parametre tahminleri ve karma model yardımı ile gerçekleştirilmiş olan sınıflandırma analizi sonucunun görüntüsü.....	192
5.36. Üç bant ve beş sınıf tahmini için Isodata sınıflandırma sonucu gri ton görüntüsü.....	193
5.37. Üç bant ve beş sınıf tahmini için Isodata sınıflandırma sonucu renkli görüntüsü.....	193
5.38. Üç bant ve beş sınıf tahmini için yapılan ön bilgilendirme.....	194
5.39. Üç bant ve beş sınıf tahmini için en kısa uzaklık sınıflandırma sonucu görüntüsü.....	194
5.40. Üç bant ve beş sınıf tahmini için Mahalanobis uzaklık sınıflandırma sonucu görüntüsü.....	195
5.41. Üç bant ve 15 sınıf tahmini için modifiye EM algoritması sonucu elde edilen parametre tahminleri ve karma model yardımı ile gerçekleştirilmiş olan sınıflandırma analizi sonucunun görüntüsü	199
5.42. Üç bant ve 15 sınıf tahmini için Isodata sınıflandırma sonucu.....	200

5.43. Üç bant ve 15 sınıf tahmini için en kısa uzaklık sınıflandırma sonucu görüntüsü.....	200
5.44. Üç bant ve 15 sınıf tahmini için Mahalanobis uzaklık sınıflandırma sonucu görüntüsü.....	201
5.45. Modifiye EM algoritması sonucu elde edilen parametre tahminleri ve karma model yardımı ile gerçekleştirilmiş olan sınıflandırma analizi sonucunun görüntüsü	210
5.46. Satürn gezegeni halkaları Isodata sınıflandırma sonucu.....	210
5.47. Satürn gezegeni halkaları en kısa uzaklık sınıflandırma sonucu.....	211
5.48. Satürn gezegeni halkaları Mahalanobis sınıflandırma sonucu	211
5.49. EM algoritması sonucu elde edilen parametre tahminleri ve karma model yardımı ile gerçekleştirilmiş olan sınıflandırma analizi sonucunun görüntüsü.....	219
5.50. Isodata sınıflandırma sonucu.....	220
5.51. Yapılan ön bilgilendirme.....	220
5.52. En kısa uzaklık sınıflandırma sonucu	221
5.53. Mahalanobis uzaklık sınıflandırma sonucu.....	221
6.1. Üç bant ve iki sınıf için sınıflandırma sonuçlarının karşılaştırmalı gösterimi.....	222
6.2. Üç bant ve üç sınıf için sınıflandırma sonuçlarının karşılaştırmalı gösterimi.....	223
6.3. Üç bant ve dört sınıf için sınıflandırma sonuçlarının karşılaştırmalı gösterimi.....	224
6.4. Üç bant ve beş sınıf için sınıflandırma sonuçlarının karşılaştırmalı gösterimi.....	225
6.5. Üç bant ve 15 sınıf için sınıflandırma sonuçlarının karşılaştırmalı gösterimi.....	226
6.6. Satürn gezegeni halkaları sınıflandırma sonuçlarının karşılaştırmalı gösterimi.....	227
6.7. En kısa uzaklık tekniğinde bazı piksellerin sonuçları.....	228
6.8. Jüpiter gezegeni atmosferi sınıflandırma sonuçlarının karşılaştırmalı gösterimi.....	229

ÇİZELGELER DİZİNİ

2.1. Landsat görevleri.....	41
2.2. TM algılayıcı karakteristiklerinin özeti.....	43
2.3. e-posta mesajlarına bulunan kelimelerin ya da karakterlerin ortalama yüzdesine eşit göstergede olan kelime ya da karakterler.....	52
2.4. Şekil 2.31'deki iki bileşenli karma örneğinde kullanılan yirmi varsayımsal veri noktaları.....	89
2.5. Karma örneği için EM Algoritmasının seçilmiş yinelemeleri.....	92

SİMGELER ve KISALTMALAR DİZİNİ

CCD	: Yükleme İliştirilimiş Araç
cos	: kosinüs
H ₂ O	: Su
O ₂	: Dioksit
O ₃	: Trioksit
µm	: Mikrometre
nm	: Nanometre
sin	: sinus
\bar{X}	: Örneklem Ortalaması
µ	: Anakütle Ortalaması
L	: Olabilirlik Fonksiyonu
f	: Fonksiyon
ln	: Doğal Logaritma
log	: Logaritma
R	: Reel Sayılar Kümesi
^	: Kestirici İşareti
∂	: Kısmi Diferansiyel
n	: Örneklem Hacmi
p	: Olasılık
P	: Olasılık

\subseteq	: Alt Küme
Σ	: Toplam
π	: 3.14159265359...
$p(\mid)$: Koşullu Olasılık
\int	: İntegral
\cap	: Kesişim
ϵ	: Elemanı
\supset	: Kapsar
$>$: Büyük
\geq	: Büyük Eşit
\cdot	: Çarpım
∞	: Sonsuz
\emptyset	: Boş Küme
$\{ \}$: Küme
d	: Diferansiyel
H_0	: Yokluk Hipotezi
H_1	: Alternatif Hipotez
AIDS	: Acquired Immune Deficiency Syndrome (Edinilmiş Bağışıklık Eksikliği Sendromu)
σ^2	: Varyans
\bar{x}	: Örneklem Ortalaması
σ	: Standart Sapma
π	: Karma Olasılık

≡	: Denk
BFGS	: Broyden Fletcher Goldfarb Shanno Algoritması
ASCII	: American Standard Code for Information Interchang (Bilgi Değişimi İçin Amerikan Standart Kodlama Sistemi)
jpeg	: Joint Photographic Experts Group (Birleşik Fotoğraf Uzmanları Grubu)
tiff	: Tagged Image File Format (İşaretlenmiş Görüntü Dosya Biçimi)
ID	: Identity (Kimlik)
Matlab	: Matrix Laboratory (Matris Laboratuvarı)

1. GİRİŞ

Uzaktan algılama hakkında bir çok tanım mevcuttur ve bu tanımlara yenileri eklenebilmektedir. Uzaktan algılama (UA) gözlemlenen konumdan farklı uzaklıktaki canlı(lar) ya da nesne(ler) ile fiziksel özelliğe sahip olmayan olgu(lar) hakkında tatmin edici bilgilere sahip olabilme bilim, teknik, kabiliyeti ve sanatıdır. Uzaktan algılama alanında uygulamalar genel olarak hava fotoğrafları ve uydu görüntülerinden elde edilen veriler ile yapılmış olup günümüzde geniş bir yelpazede ayrıntıları gittikçe artan bir şekilde devam etmektedir. Bu alanlara örnek olarak istatistik, matematik, jeofizik, jeoloji, maden, ziraat, peyzaj planlama, tıp, biyoloji gibi anabilim dalları sayılabilir: Bunun yanı sıra uzaktan algılama, görüntü işleme mikrobiyoloji gibi farklı bilim dallarının ayrıntılı alt başlıkları olarak da karşımıza çıkmaktadır.

Uzaktan algılamanın en yaygın olarak uygulanan biçimi uzaktan algılanmış uydu verileri ile yapılmaktadır. Uydulardan elde edilen veriler araştırmacılara yaşadığımız gezegen dünyaya ait hiçbir yerde bulunamayan bilgiler vermektedir. Doğanın kendisine ait işleyiş biçimini, gizemlerini ve kendine ait mekanizmasını yani doğanın lisanını uzaktan algılama uydularının elde ettiği görüntüler daha iyi anlamamızı sağlar. Bu sayede madenleri, doğal kaynakları, çevre kirliliğini, volkanları, fay hatlarını tespit eder ve tespit ettiğimiz bu sıra dışı yer gerçeklerine ait yorumlama ve analizler yapma imkanı bulup, doğaya ait yeni keşiflere ulaşma imkanını elde etmiş oluruz.

Yeryüzünden yaklaşık 500-800 km yukarıda elde edilen uzaktan algılama verileri bizlere yeryüzü irtifasından göremeyeceğimiz ve algılamayacağımız gerçekleri anlamamızı ve keşfetmemizi sağlar. Bu keşfe ait görüntüler gezegenimiz için olabileceği gibi sonsuz boşluktaki evrene ait olan, insan gözünün algılama sınırı içinde ya da dışında yer alan gezegenler, ya da o gezegenlerin atmosferik yapısı belki de herhangi bir sıra dışı nesneye ait olabilir.

Yukarıda bahsedilen yeni keşiflerin görüntü yolu ile elde edilmesindeki etkili olan analizlerden birisi hiç şüphesiz ki istatistiksel sınıflandırma analizidir. İncelediğimiz görüntüye ait nesnenin hangi sınıfa ait olduğu ya da olmadığı çok önemli ve aynı zamanda çok kritik bir bilgidir. Bir nesnenin gerçekte ait olduğu nesneye ait olup olmadığı çoğu durumlarda hayati bir öneme sahiptir. Örneğin

ileride gidilmesi düşünölen Mars gezegeninin atmosferik yapısının, yüzey yapısının ve muhtemel doğal kaynaklarının doğru tespiti gelecekte uzay yolculuğunun yapılmaya değer olup olmayacağı ya da Mars gezegeninde yaşanıp yaşanmayacağı kararının verilmesine neden olacaktır.

Benzer şekilde sondaj yapılacak bir bölgenin istatistiksel sınıflandırma analizi ile yanlış ya da doğru tespit edilmesi, o bölgeye yapılacak sondaj için masrafların boş yere yapılıp yapılmayacağını belirler. Bu ve benzer nedenlerden dolayı, astronomide, atmosferik tahminlerde, doğal enerji kaynaklarının tespitinde, maden aramalarında, peyzaj planlamada ve bir çok alanda doğru istatistiksel sınıflandırma, karar verme sürecini direkt etkileyen en önemli araçtır.

Bu durumda uzaktan algılama verilerine sınıflama analizini doğru ya da yanlış yapmak çok büyük öneme sahiptir. Yapılan yanlış sınıflandırmalar, bazı teknik eksiklik ya da hatalara bağılı olabileceğı gibi (görüntünün atmosferik düzeltmelerinin yapılmaması gibi), görüntünün çözünürlüğünün yetersiz olması ya da yapılan analize bağılı yetersizliklerden de kaynaklı olabilir.

Kimi durumlarda mevcut uzaktan algılama sınıflandırma tekniklerinden bazıları çok sınıflı karmaşık görüntüye sahip veriler için yetersiz kalabileceğı gibi, bazıları ise basit düz ve oldukça sade olan az sınıflı ve sade görüntüye sahip veriler için yetersiz kalabilmektedir.

Karma dağılım birden fazla dağılmış bileşenler yani sınıflar için kullanılan dağılımdır. Bu kavramı uzaktan algılanmış uydu verisi için düşünecek olursak, kara ve deniz olarak düşündüğümüz iki yer gerçeğı nesnesine ait uzaktan algılama verilerini birbirinden ayırt etmek için düşünebiliriz. Bu temel sınıflandırmada yapılan karma dağılımı farklı metodolojilerde gerçekleştirmek mümkündür.

EM algoritması Expectation Maximization orjinal isminin kısaltılmış halidir. Beklenen değeri en fazla yapma anlamında Türkçe'ye çevirebiliriz. İki veya daha çok bileşenli dağılımların parametre tahminlerinin bulunmasını sağlar. Bu parametreler sayesinde sınıflandırma yapılacak her bir bileşenin sınırları da belirlenmiş olur ve uzaktan algılama verisindeki her bir aday piksel, ait olduğu doğru sınıfa ya da kümeye atanır.

Çoklu karma normal dağılımında parametre tahminleri EM algoritması yardımıyla yapılıp, elde edilen parametreler yardımı ile oluşan yoğunluk fonksiyonları sayesinde yapılan sınıflandırma analizinde, önemli sorunlardan iki

tanesi, EM algoritmasının ilk tahmin değerlerine karşı duyarlı olması ile, varyans kovaryans matrisinin birleşenlerden biri ya da daha fazlası için tekil olması sorunudur. İşte bu tezde uydu verileri için ilk tahmin değerlerinin EM algoritmasına duyarlılık sınırları ve radyometrik çözünürlük ile ilişkisi incelenmiş ve bir ya da daha fazla bileşen için varyans kovaryans matrislerinin tekil olması durumu modifiye edilen teknik ile önlenmiştir.

Bu çalışmada çoklu normal karma dağılımın parametre tahminleyicisi olan EM algoritması ile yapılan parametre tahminleri yardımı ile uzaktan algılanmış uydu verileri için yapılan sınıflama analizi, bazı klasik sınıflandırıcılar ile karşılaştırılmış, ve bazı durumlarda modifiye edilmiş EM algoritması ile yapılan parametre tahminleri yardımı ile uzaktan algılama verileri için yapılan sınıflama analizi, yine aynı bazı klasik sınıflandırıcılar ile karşılaştırılmıştır. Bu karşılaştırmalarda doğru sınıflandırma yani güvenilirlik ve etkinlik ön planda tutulmuştur. Örnek verilmesi gerekirse; uzaktan algılanmış belirli bir uydu verisi için yer gerçeğinin gösterdiği sınıflardan birisi kıyı olsun ve bu sınıfa nirengi sınıfı denilsin. Uzaktan algılamada kullanılan bazı klasik sınıflandırıcılar yardımı ile sözkonusu uydu verisi için elde edilen sınıflandırma sonuçları, yine aynı söz konusu uydu verisi için modifiyesiz ya da modifiyeli EM algortması yardımı ile elde edilen sınıflandırma sonuçları ile karşılaştırıldığında, nirengi sınıfı olan kıyı sınıfı hangi sınıflandırma analizi sonucunda ortaya çıkmış ise o sınıflandırıcı daha güvenilir denilebilir. Nirengi sınıflarının sayısı arttırılabilir.

Bu tezde ikinci bölümde uzaktan algılamaya dair temel kavramlar ve temel işlemler açıklanmış, istatistiksel öğrenme kavramı üzerinde durulmuş, istatistiksel öğrenme kavramının kullanım alanlarından örnekler verilerek nasıl kullanıldığı anlatılmıştır. Yine aynı bölümde istatistiksel öğrenmenin uzaktan algılamada nasıl kullanıldığı kavramı ele alınmış ve hangi tip klasik sınıflandırıcıların nasıl çalıştığı avantajları ve dezavantajları anlatılmıştır. Daha sonra istatistiksel öğrenme tabanlı klasik ve şimdiye kadar bilinen EM algoritmasına yakın iyi sınıflandırıcıların teorik yapıları anlatıldıktan sonra uzaktan algılama ve uydu çoklu bant sistemi açısından teorik yapının uygulamadaki formüllere nasıl dönüştüğü anlatılmıştır. Aynı bölümde Bayes Kuramı ve ayrıca EM algoritması ayrıntılı bir şekilde anlatılmıştır. Bu tezin katkıları öncelikle tek boyutlu herhangi sayıda bileşen için EM algoritması yardımı ile parametre tahmini ve bileşenlerin olasılık yoğunluk

fonksiyonları ve karma Gauss modeli geliştirilen matlab kodu sayesinde bulunmuştur. EM algoritmasının uzaktan algılanmış uydu verilerine uygulanması için gereken 3 boyutlu EM algoritması için matlab kodu geliştirilmiştir. Böylece uzaktan algılama verisinin herhangi üç kombinasyonu yani üç bantı için EM algoritması yardımı ile sınıflandırma yapılmıştır. Uzaktan algılama verileri uzaktan algılama paket programlarında bulunmayan EM algoritması yardımı ile uydu verilerini sınıflandırması ayrıca bant sayısının ve bileşen sayısının yani sınıfın fazla olduğu bazı durumlarda, bir ya da daha çok sınıf için söz konusu olan varyans kovaryans matrislerinin tekilleşmesi problemini çözülmüş yani EM algoritması modifiye edilmiş bu sayede başarılı görüntü sınıflandırma sonuçları elde edilmiştir.

Modifiyesiz ve modifiyeli EM algoritması yardımı ile elde edilen parametre tahminleri ve karma model yardımı ile gerçekleştirilmiş olan sınıflandırma analizleri sonuçları, popüler ön bilgilendirmesiz ve ön bilgilendirmeli uzaklık esaslı sınıflandırıcılardan olan; Isodata, en kısa uzaklık ve Mahalanobis uzaklık sınıflandırma analizlerinde sınıflandırması yapılan uzaktan algılama verilerinin büyük bir çoğunluğundan daha doğru sınıflandırma yapması yani daha güvenilir olması ile daha etkin olması bu teze ait hipotezi oluşturur. Bu tezin temel amacı ön bilgilendirmesiz ve ön bilgilendirmeli uzaklık esaslı ve olasılık dağılımı kullanmayan sınıflandırıcılara göre büyük bir güvenilirlik ile daha etkin ve güvenilir sonuçlara ulaşmayı sağlayacak, istatistiksel öğrenme temelli bir yeni modifiye sınıflandırıcı geliştirmektir. Böylece özellikle uzaktan algılamada sınıflandırma çalışması için ön bilgilendirmeli (kontrollü) sınıflamanın mümkün olmadığı, geçmiş tarihli görüntülerin sınıflanması, uzay gözlemlerine dayalı yapılacak sınıflandırmalar gibi durumlarda kullanılabilir ön bilgilendirmeli sınıflandırma tekniklerine en yakın ve hatta daha iyi sonuca ulaşılmasını sağlayacak istatistiksel öğrenme tabanlı bir sınıflandırıcı geliştirilmiş olacaktır.

Bu çalışmada bir çok uzaktan algılama kaynağında denetimli ya da denetimsiz, eğitilmiş ya da eğitimsiz gibi isimlerle kullanılan kavramlar yerine (Mola 2005) tarafından önerilen ön bilgilendirmeli ya da ön bilgilendirmesiz kavramları kullanılması uygun görülmüştür.

2. KURAMSAL TEMELLER

Bu bölümde ileri bölümlerde anlatılacak olan istatistiksel öğrenme tekniklerinin uzaktan algılamaya uygulanışının daha iyi anlaşılabilmesi için uzaktan algılamanın kuramsal temel kavramları ve uzaktan algılamada temel kavramların içeriğinde olan uzaktan algılama prensiplerinin ne olduğu, elektromanyetik ışınım, elektromanyetik spektrum, ışınım kanunları elektromanyetik ışınımın atmosfer ile etkileşimi ve yüzey ile etkileşimi, spektral imza, dijital görüntü kavramının ortaya çıkışı ve piksel kavramı, algılayıcılar, çözünürlük kavramı, istatistiksel öğrenme kavramı ve kullanım alanları, istatistiksel öğrenme tabanlı bazı güçlü sınıflandırıcılar ve teorik açıklamaları ile EM algoritması açıklanacaktır.

2.1. Uzaktan Algılamada Temel Kavramlar

Uzaktan algılama kavramının anlaşılması için aşağıda bazı ünlü uzaktan algılama tanımları verilmiştir:

Uzaktan algılama birçok kez tanımlanmıştır. Fakat basitçe tanımlanmak gerekilirse bir nesne hakkında ona dokunmadan birşeyler söylebilme bilim ve sanattır (Fischer ve ark., 1976'dan akt. Campbell ve Wynne 2011). Uzaktan algılama bir objeye dokunmadan ya da temas sağlamadan fiziksel veri kazanımıdır (Lintz and Simonett, 1976'dan akt. Campbell ve Wynne 2011). Uzaktan algılama hedeften belirli bir uzaklıkta araçlarla gözlem yapmaktır (Barrett and Curtis, 1976'dan akt. Campbell ve Wynne 2011). En geniş anlamı ile "uzaktan algılama" terimi sadece "belirli bir mesafeden keşif" anlamına gelir (Colwell, 1966 'dan akt. Campbell ve Wynne 2011).

White (1977)'ye göre uzaktan algılama algılayıcısının görüş alanının içinde bulunan hedef alanından tespit ve elektromanyetik ışınımı kayıt etmesiyle ilgilidir. Bu radyasyon hedef alanlarının ayrı ayrı bileşenlerinin doğrudan kaynağı olabilir; hedeften gelen güneş enerjisinin yansımış hali olabileceği gibi; sensörün kendisinden direkt olarak hedef alana enerji aktarımının yansımaları da olabilir (Campbell ve Wynne 2011). National Academy of Sciences (1970)'e göre uzaktan algılama terimi birkaç bilim adamı tarafından çok büyük mesafelere ait uzaktaki nesnelere (dünya, ay, ve gezegen yüzeyleri ve atmosferleri, yıldızlara ait ve

galaktik olaylar gibi) hakkında çalışmak için bu günlerde kullanılmaktadır. Geniş tanımı ile uzaktan algılama modern algılayıcılar, veri işleme ekipmanları, bilgi teorisi ve işleyiş metodolojisi, iletişim teorisi ve cihazları, uzay ve hava araçları ve büyük sistemler teorisi ve Dünya'nın yüzeyine hava ya da uzay araştırmaları taşıma amaçlı uygulamaların bileşik etkilerine değinir (Campbell ve Wynne 2011).

Swain and Davis (1978)'e göre günümüzde en sık ölçüm yapılan uzaktan algılama sistemleri ilgili nesnelere gelen elektromanyetik enerjidir. Diğer olasılıklar olmasına rağmen (örneğin sismik dalgalar, ses dalgaları ve yerçekimi kuvveti) dikkatimiz elektromanyetik enerji ölçen sistemler üzerinde odaklanmıştır (Campbell ve Wynne 2011).

İnsanlar olarak, bizler uzaktan algılama sistemleri ile son derece benzeriz. Etrafımızdakiler hakkında daha fazla bilgi için görsel algılamamıza güveniyoruz. Sensörlerde olduğu gibi, ancak, gözlerimiz fazlası ile:

- Sadece elektromanyetik enerjinin görünür aralığında algılama ile sınırlıdır.
- Görüş alanı vücudumuzun bulunduğu konum tarafından belirlenir.
- En son gördüğümüzün son kayıt olması yetersizliktir.

Bu sınırlamalardan dolayı çevrenin fiziksel özellikleri görmeyi ve kaydetme yeteneğini arttırmak için insanlar sürekli olarak teknolojik araçlar geliştirmeye çalışmışlardır. Hava fotoğrafçılığının kullanımının erken zamanlarında uzaktan algılamanın analiz etmede, nitelendirmede ve çevremiz hakkında karara varmada değerli bir araç olduğunun farkına varılmıştır. 30 yıl öncesine kadar uzaktan algılama teknolojisi üç cephede ilerlemiştir:

- Ağırlıklı olarak askeri kullanımlardan çeşitli çevre analiz uygulamalarının kara, deniz ve atmosfer konuları ile ilgili olanları,
- Fotografik sistemlerden algılayıcılara kadar enerjiyi elektromanyetik spektrumun birçok parçasından elektronik sinyale çeviren alanlarda,
- Uçaklardan uydu platformlarına kadar olan alanlarda

Bugün, biz uydu uzaktan algılamayı, uydu-kaynaklı algılayıcıları kullanmak suretiyle Dünya ve Dünya'ya ait çevre tarafından yansıtılan ve yayılan elektromanyetik radyasyona dair sonradan analiz yapmak ve bilgi çıkartmak için gözlemlemek, ölçmek ve kayıt etmek gibi tanımlarız (Anonim 2014a).

Uzaktan algılama ile ilişkili alanların benzerlikleri ve farklılıklarına değinilecek olunursa, çeşitli karşılaştırmalar aşağıdaki gibidir;

Uydu görüntüleri ile haritaların karşılaştırılmasında, uluslararası kartografya birliğine göre bir harita “coğrafi gerçekliğin seçilen özelliklerini ya da karakteristiğini temsil eden konvensiyonelleştirilmiş görüntü mekansal ilişkileri birincil öneme sahip olduğunda kullanılmak için dizayn edilmiştir”. Bu tanım her haritanın seçilmiş alanı temsil etmesinin süreci olduğunu (ve ayrıca sembolizasyon, özetleme ve genelleme), ayrıca haritanın bilimsel kesinliğinin genel havasını gösterir. Fakat bir harita bizlere dünya hakkında ne biliyorsak o bildiğimizi gösterir. Bu çok karmaşık bir konudur ve aşağıdakilerden oluşmuştur:

- Teknolojik ve ölçüm aletlerinin sınırlılığı sorunu,
- Haritada neye inanıyorsak onun var olması,
- Haritada neyi düşünüyorsak onun önemli olması,
- Haritada neyi istiyorsak onun arzulanması

Böylece bir harita subjektiftir. Biz her zaman haritanın üzerine ne koymak istersek ve nasıl göstermek istersek haritanın oluşmasına da öyle karar veririz. Uzaktan algılama görüntüsü bunun tersidir. Elektromanyetik sensöre ulaşan objektif kayıtlar uzaktan algılama görüntüleridir (Anson ve Ormeling 1993; Portugaly 1996).

Diğer bir önemli farklılık ise, bir harita kağıt üzerindeki dünyanın herhangi yüzey şekilleri ve yükseklik farkları olmaksızın izdüşümüdür.

Durum böyle iken uzaktan algılama görüntüsü hem yüzey şekilleri ve yükseklik farkları hem de geometrik bozuklukları gösterir.

Uzaktan algılama ve coğrafi bilgi sistemlerini karşılaştırdığımızda; CBS (Coğrafi Bilgi Sistemleri) aşağıdaki durumlara olanak sağlayan bir çeşit sistemdir:

- İlişkili mekansal verilere ve çizelge, tablo ya da liste halinde verilmiş verilerle
- Çizelge, tablo ya da liste analizi ve mekansal analiz icra etme.
- Haritanın dizaynının düzenlenmesi ve sembolize edilmesi.

Bir CBS yazılımı hem vektör hem de raster verileri idare edebilir. Uzaktan algılama verileri ise raster veri tipine aittir ve genellikle normal CBS'in sağlamadığı özel veri yönetimi usüllerine ihtiyaç duyar. Buna rağmen uzaktan

algılama analizi tamamlandığında sonuçlar genellikle CBS ile ya da veri tabanı ile bütünüştür. Daha ileri düzey analizlerde (diğer katmanlar ise katmanları üst üste bindirme gibi) geçen yıllarda çok ve daha çok vektör kapasitesi uzaktan algılama yazılımlarına atanmış ve uzaktan algılama fonksiyonları CBS modüllerinin içine eklenmiştir. Aslında uzaktan algılama coğrafi bilgi sistemlerinin gereksinim duyduğu yüksek doğrulukla ve güncel veri gereksinimini karşıladığı için çok önemlidir (Anson ve Ormeling 1993; Portugaly 1996).

(Anson ve Ormeling 1993; Portugaly 1996)'a göre uzaktan algılama ile geleneksel fotogrametri yöntemleri karşılaştırıldığında; her iki sistem de Dünyanın üst yüzeyi ile ilgili verileri elektromanyetik radyasyonun ölçülmesi ya da hava araçlarındaki sistemler sayesinde toplar. Aşağıda ana farklılıklar şu şekilde verilebilir:

Hava fotoğrafları analog bir cihaz tarafından elde edilir: kameranın (fotogrametrik) filmi, ardından dijital ortama dönüştürülmesi için taranır. Uzaktan algılama verileri genellikle dijital CCD kameralarından elde edilir. Bir filmin avantajı yüksek çözünürlüklü olmasıdır (granüllü yapı). Durum böyle iken CCD kameralarının avantajı algılayıcıya ulaşan ışınımı kuantatif olarak ölçebilmemizdir (gri değerleri içeren ölçü çubuğu yerine parlaklık değerleri). Böylece uzaktan algılama verileri örneğin enerji dengesinin fiziksel denklemlerine entegre edilebilir (Anson ve Ormeling 1993; Portugaly 1996).

Hava fotoğrafları tüm resim için bir örnek alan merkezi bir projeksiyondur (perspektiftir). Bir uzaktan algılama görüntüsü sıra sıra oluşumdur; böylece geometrik düzeltme her bir sıra ile (ya da piksel) merkezi projeksiyon olarak davranmaya ihtiyaç duyacağından çok daha fazla karmaşıktır.

Hava fotoğrafları genellikle sadece ışığın görünür aralığında verileri toplar (yakın kızılötesi ışınımaya duyarlı özel filmler vardır). Durum böyle iken uzaktan algılama sensörleri elektromanyetik spektrum tüm aralığı boyunca radyasyonu ölçmek için tasarlanmıştır.

Hava fotoğrafları genellikle uçaklardan elde edilirken uzaktan algılama görüntüleri uydulardan elde edilir.

Her iki sistemde atmosferik dağıtımdan etkilenir. Hava fotoğrafları esas olarak bulanıklık (bu ışığın saçılımıdır, gökyüzünü mavi yapan süreç), uzaktan algılama görüntüleri ayrıca absorbe (emme) sürecinden sonra oluşur. Hava

fotoğraflarında atmosferik düzeltmeler resmin çekilmesi esnasında yapılır (bir filtre kullanarak), ya da uzaktan algılamada olduğu gibi görüntünün çekilmesinden sonra yapılan işlemler gibi. Termal uzaktan algılama algılayıcıları gece işlem yapabilirler ve radar verileri hemen hemen havadan bağımsızdır.

Fotogrametride gösterilen ana çaba tam olarak üç boyutlu model oluşturmak içindir. Nesnelerin sınırlarını ve konumlarını yüksek kesinlik ile çizmek ve sayısal yükseklik modeli (Digital Elevation Model) oluşturmak için karmaşık geometrik düzeltmeler uygulanır. Uzaktan algılamada ana çaba ise gelen elektromanyetik spektrumun atmosferik düzeltmelerini kullanılarak, değişik kategorilerdeki piksellerin sınıflandırılması için karmaşık istatistiksel metotları ve bu verileri uzayda dolaşan ve nesnelere etkileşim halinde bulunmak gibi durumlardaki ışığı etkileyen bilinen fiziksel süreçlerle analiz etmektir.

Uzaktan algılama görüntüleri bölge üzerindeki durumlar için son derece kullanışlıdır

Kıtasal hatta küresel ölçekte her bir piksel aslında geniş yer gerçeğini temsil etmek üzere her zaman görüntü alınabilir (örneğin belirli bir dereceden sabit tutup ya da aynı yeri 15 günde bir ziyaret ederek).

Uzaktan algılama görüntülerinin yorumları personel eğitimini gerektiren fazla zorlu bir süreçtir. Oysa hava fotoğraflarını daha kolay bir şekilde yorumlanabilir.

Uzaktan algılama ile sonar batimetrik sistemler karşılaştırıldığında; denizin yüzeyinde araştırma yapan sonar uzaktan algılama gibi düşünülebilir. Sonar, uzaktan algılamanın aktif tipidir. Radar gibi; dalgalar bir dış kaynağa bağlı değil, elektromanyetik dalgaların iletimi ve alımı arasındaki zaman ölçümü ve elektromanyetik dalgaların boyutu ürettiğimiz araçlarla yapılır. Fakat kullanılan elektromanyetik radyasyon değil ses dalgalarıdır.

Her iki sistemde dalgaları hava su yoluna karışarak bizim elde ettiğimiz verilere gürültü ekler ve bu veriler üzerinde yapılacak düzeltmelerin toplanan ham verilere uygulanması gerekir. Uzaktan algılamada buna rağmen radar daima hava şartlarından bağımsız olarak düşünülmüştür ve atmosferik dağılımlar pasif uzaktan algılamayı etkiler. Ham verilere yapılacak düzeltmelerin gerekli olduğu düşünüldüğünde her iki uzaktan algılama sistemi de verilerin bağımlı olduğu alana göre değişen düzeltmeye bağımlı olur (Anson ve Ormeling 1993; Portugaly 1996).

Örneğin sonar sisteminde gemi tarafından ölçülen sıcaklık ve basınç ölçülme esnasındaki tuzluluk, ya da uzaktan algılama meteorolojik radyasyon ile atmosferik profil parametrelerin ölçülmesi bu düzeltmelerdendir. Sonarın ana kullanımı denizden batimetri (derinlik ölçümü) üretmek içindir. Uzaktan algılama teknikleri ise daha çok objelerin fiziksel farklılıklarına göre onların özelliklerinin belirlenmesi üzerine odaklanır. Tekli ya da çoklu sonarlar havadan taşınan lazer tarayıcılar ile karşılaştırılabilir. Her iki sistemde X,Y,Z koordinatlarını içeren verileri için nokta (vektör) oluşturur. Bu veriler gürültünün ortadan kaldırılması için daha ileri seviyede süreç sonrası işlemlere ihtiyaç duyar. Topoğrafyanın aksine batimetri ilave karmaşık gelgit düzeltmelere ihtiyaç duyar (Anson ve Ormeling 1993; Portugaly 1996).

2.1.1. Uzaktan Algılamanın Kullanım Alanları

Uzaktan algılamanın değişik kullanım alanları aşağıda verilmiştir:

Tarım hem gelişmiş hem de gelişmemiş ülkelerin ekonomilerinde baskın rol oynar. Uydular ve hava araçları ile elde edilen görüntüler ekinleri sınıflandırmak, onların sağlığını ve canlılığını incelemek ve tarım uygulamalarını görüntülemek için haritalama aracı olarak kullanılmaktadırlar. Uzaktan algılamanın tarımsal uygulamaları şu şekilde sıralanabilir:

- Ürün tipi sınıflandırma
- Ürün koşulları değerlendirmesi
- Rekolte tahmini
- Toprak karakteristiklerini haritalama
- Toprak yönetimi uygulamalarını haritalama
- Uygunluk izleme (tarım uygulamaları)



Şekil 2.1. Uzaktan algılanmış bir tarla görüntüsü (Anonim, 2014b)

Ormanlar, gıda, barınak, doğal yaşam alanı, yakıt, tıbbi malzemeler ve kağıt gibi günlük malzemeleri sağlayan değerli kaynaklardır. Ormanlar, Dünya'nın karbondioksit (CO₂) dengesini sağlayarak karbondioksit (CO₂) dengesi açısından atmosfer, geosfer ve hidrosfer arasında anahtar bağlantı gibi davranarak önemli bir rol oynar (Anonim, 2014b). Uzaktan algılamanın orman uygulamaları şu şekilde sıralanabilir:

- Keşif haritalama: Uzaktan Algılama yardımıyla ulusal orman ya da çevre ajansları tarafından karşılanacak, güncellenmiş orman örtüsünün, değişimini izlemek, ormanın biyofiziksel özelliklerini ölçmek, keşfetmek ya da bulmaktır.
- Ticari ormancılık; Ticari ormancılık şirketleri ve kaynak yönetimi ajansları için uzaktan algılama kullanımının önemi, envanter ve harita uygulamaları; ürün miktarına ilişkin bilgi toplama, kereste temini için envanter bilgilerinin güncellenmesi, geniş orman tipi, bitki örtüsü yoğunluğu ve biyokütle ölçümleridir.
- Çevresel izleme: Çevresel koruma ile ilgili otoriteler, uzaktan algılama yardımıyla ormanların çeşitliliği, sağlığı ve miktarını izleme ile ilgili bilgileri elde edebilmektedirler (Anonim, 2014b).

Jeoloji yer şekilleri, yer yapıları ve yeraltını içeren Dünya'nın kabuğunun oluşumu ve değişimi fiziksel işlemlerini anlamaya yönelik yapılan çalışmaları içerir. Mineral ve hidrokarbon kaynakları genellikle toplumun yaşam koşullarını yükseltmek için en sık çokca keşfetme ve kullanma olarak anlaşılır. Uzaktan algılamanın jeoloji uygulamaları şu şekilde sıralanabilir:

- Yüzeysel birikinti haritalama, anakaya haritalaması
- Litolojik haritalama
- Yapısal haritalama
- Mineral araştırması
- Hidrokarbon araştırması
- Çevresel jeoloji
- Jeobotanik
- Temelhat ve altyapı
- Çökeltme haritalaması ve izlenmesi

- Durum haritalaması ve izlenmesi
- Jeolojik tehlike haritalaması
- Yerkabuğu hareketleri gibi (Anonim, 2014a).

Hidrojeoloji, Dünya'nın yüzeyindeki su ile ilgili olarak araştırma yapar. Suyun yer küredeki döngüsünü, taşkın sel, heyelan çığ gibi afetler ile yer altı ve yüzey sularını inceler. Hidrolojideki uzaktan algılama uygulamaları şu şekilde sıralanabilir:

- Sulak alanların haritalanması ve izlenmesi
- Toprak nem tahmini
- Kar yığını izlenmesi,
- Kar yığının ölçülmesi,
- Kar ve su eşdeğerliğinin belirlenmesi,
- Nehir, göl ve karasal buzlarının izlenmesi,
- Sel haritalanması ve izlenmesi,
- Buzul hareketleri incelenmesi,
- Nehir, delta değişim tespiti,
- Havza haritalaması,
- Drenaj,
- Sulama kanalı sızıntılarının tespiti,
- Sulama programı oluşturma ve benzeri (Anonim, 2014a).

Uzaktan algılamanın haritalama uygulamaları şu şekilde sıralanabilir:

- Alan ölçümleri
- Sayısal yükseklik modeli oluşturulması
- Topografik haritalama
- Tematik haritalama
- Arazi örtüsü haritalaması
- Yol ve benzeri üst ve alt yapı elemanlarının haritalanması gibi

Anonim (2014a)'e göre okyanuslar ve denizler sadece değerli besin ve biofiziksel kaynakları sağlamakla kalmaz, bunun yanında ulaşım yolları olarak yani hava sistemini oluşturma ve karbon dioksit (CO₂) yatağı olarak da hizmet eder. Denizler ve okyanuslar bunun yanında Dünya'nın hidrolojik dengesinin önemli bağlantısıdır (Anonim, 2014a). Ayrıca denizler hem balıkçılık, hem de

ulařım aısından ok nemlidir. Anonim, (2014a)'e gre uzaktan algılamanın okyanus, deniz ve kıyı izleme uygulamaları řu řekilde sıralanabilir:

- Okyanus model tanımlamaları ve batimetri,
- Fırtına tahmini,
- Balık stoęu ve deniz memelilerini deęerlendirme,
- Su sıcaklıęı kalitesi ve kirlilięini deęerlendirme ve izleme,
- Petrol sızıntısı haritalanması ve izlenmesi,
- Nakliye ve deniz ulařımı yntemi ve takibi,
- Gelgit ve fırtına etkileri,
- Kara ve su arayznn ayrımı,
- Kıyı zelliklerini haritalama, plaj dinamikleri,
- Kıyı bitki rts tanımlama,
- İnsan etkinlięi ve etkisi (Anonim, 2014a).

Uzaktan algılamanın kullanıldıęı dięer alanlar řu řekilde sıralanabilir:

- Buz yoęunluęu ve durumu,
- Buz tipi, yaşı, hareketi,
- Buzdaęı algılama ve izleme,
- Yzey topografisi,
- Navilgasyon, gvenli nakliye yolları, kurtarma,
- Yaban hayatı yařam alanı,
- Kirlilik izleme,
- Meteorolojik, kresel deęiřim arařtırmaları,
- Doęal kaynak ynetimi,
- Savunma ve gvenlik amalı uygulamalar,
- Yaban hayatını koruma,
- Coęrafi bilgi sistemleri iin sınır izgisi haritalanması,
- Kentsel geniřleme ve deęiřim,
- Sismik, keřif ve kaynak ıkartma faaliyetleri iin rota ve lojistik planlama,
- Hasar tespiti,
- Vergi ve mlkiyet deęerlendirmesi iin yasal sınırlar,
- Hedef belirleme (Anonim, 2014a).

2.1.2. Uzaktan Algılama Prensipleri

Uzaktan algılama enstrümanları fotoğrafik (film bazlı kameralar) ve fotoğrafik olmayan algılama sistemlerini (radyometreler, dijital kameralar, radar sistemleri ve elektro optik tarayıcılar) içerir. Şu andaki kullanılmaya hazır operasyonel uzaktan algılama sistemleri özel Dünya gözleme görevleri için dizayn edilmiştir (Rashed ve Jürgens 2010).

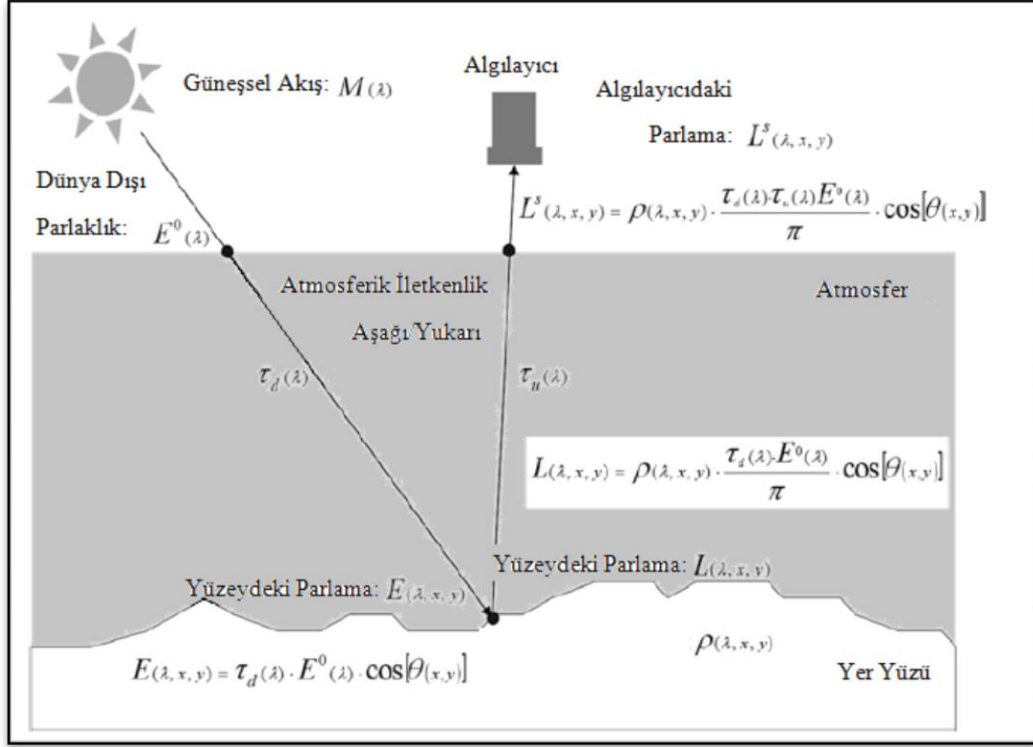
Uzaktan algılama için genel bir referans çerçevesi olarak, aktif uzaktan algılama sistemleri ile pasif uzaktan algılama sistemleri arasında öncelikli bir ayırım vardır. Pasif uzaktan algılama sistemi yansıyan güneş enerjisinde olduğu gibi zaten ortamda mevcut olan saçılan enerjiyi kayıt eder. Aktif uzaktan algılama sistemi ise bir enerji demeti gibi kendi sinyalini kendisi üretir ve daha sonra sensöre yansıyarak gelen ışının bileşenini kaydeder. Radar ve lidar aktif sisteme örnek teşkil eder (Myers ve Patil 2006).

Rashed ve Jürgens (2010)'a göre spektral sinyal uzaktan algılama ile tespit edilen yüzeydeki objelerin en önemli özelliklerinden birisidir (Şekil 2.2). Enerjinin miktarı ve spektral nitelikleri uzaktan algılama sistemi ile ölçülür ve bu durum güneşten gelen, radyasyonun ne ölçüde atmosfer tarafından değiştirilmiş olduğuna ve fiziksel ve geometrik yansıma derecesi ve de algılayıcı (sensor) spektral bantlardaki radyasyonu ölçer. Bu belirli bir dalga boyunda ya da belirli bir dalga boyu aralığında (bant genişliği) üzerinden tanımlanabilir. Spektral bantların sayısı, bantların bant genişlikleri ve elektromanyetik spektrum boyunca olan konumları, sensörlerin spektral kabiliyetlerini ya da spektral çözünürlüklerini belirler (Rashed ve Jürgens 2010).

2.1.3. Elektromanyetik Işınım


Uzaktan algılama için ilk gereksinim hedefin aydınlatılmasını (ya da enerjinin hedef tarafından olan saçılımını) sağlayacak elektromanyetik ışınım biçimindeki enerji kaynağıdır. Tüm elektromanyetik ışınım, dalga teorisinin temellerine göre tahmin edilebilir bir şekilde özelliklere ve davranışlara sahiptir: Elektromanyetik ışınım elektriksel alan içerir. Bu elektriksel alan elektromanyetik ışınımın ilerlediği yöne dik bir büyüklük olarak değişir. Bir manyetik alan elektrik alanına dik açılı bir şekildedir. Her iki alan da ışık hızında hareket ederler.

Elektromanyetik ışınının iki karakteristiği özellikle uzaktan algılamayı anlamak için önemlidir.



Şekil 2.2. Spektral sinyal (I=dalga boyu, q=yerel geliş açısı, x/y= Dünya'nın yüzeyindeki konum) (Schowengerdt, 1997'den akt. Rashed ve Jürgens 2010).

Bu iki karakteristik dalgaboyu ve frekanstır (Şekil 2.3). Dalga boyu bir dalga devirinin ardışık dalga tepelerinin arasındaki ölçülebilir uzunluğudur. Dalga boyu genellikle Yunan harfi lambda (λ) ile gösterilir.



Şekil 2.3. Farklı dalga boylarında elektromanyetik ışınım. (Köhl ve ark. 2006'den akt. Canada Centre for Remote Sensing 1998)

Dalga boyu metre ile ya da metrenin bazı katları olan nanometre, mikrometre ya da santimetre ile ölçülür. Frekans birim zaman başına belirli bir noktadan geçen dalga tepelerinin sayısını ifade eder. Frekans normalde Hertz ile ve Hertz'in çeşitli katları ile ölçülür. Dalga boyu ve frekans aşağıdaki formüldeki ilişkiye sahiptir:

$$c = v\lambda \quad (2.1)$$

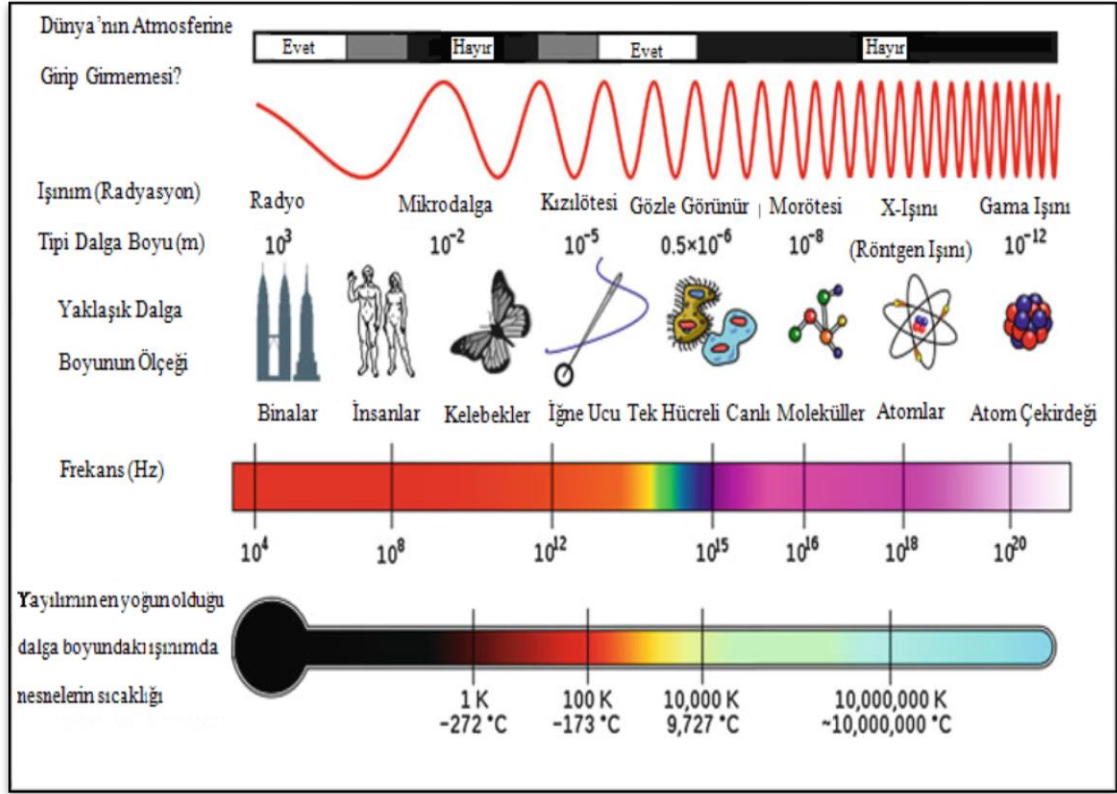
Eşitlik 2.1'de c ışığın hızı (3×10^8 m/s), v frekanstır (saniyedeki devir, Hertz) ve λ ise metre cinsinden dalga boyudur.

Bu eşitlikten dalga boyu ve frekansın birbirleri ile ters ilişkili olduklarını görmekteyiz. Dalga boyu kısalıdıkça frekans artmakta ve bu durumun tersi de doğru olmaktadır. Dalga boyu ve frekans açısından ışınımı anlamak görüntülerden çıkarılacak bilgileri değerlendirmek açısından çok önemlidir (Köhl ve ark. 2006).

2.1.4. Elektromanyetik Spektrum

Elektromanyetik ışınım (EMR) ışınların ışık hızı ile harmonik dalga desenli olarak hareket etmesi olarak tanımlanabilir. Görünür ışık sadece (EMR)'nin bir biçimidir; diğer biçimleri radyo dalgalarını, kızılötesi ve gama (gamma) ışınlarını içerirler. Birlikte, tüm bu tiplerin hepsi elektromanyetik spektrumu oluştururlar. Şekil 2.4'de gösterildiği üzere elektromanyetik ışınımın değişik formları hem frekans ve hem de dalga boyu açısından spektrumun içerisinde değişirler (Khorram ve ark. 2012).

Dalgaboyu dalga tepesindeki bir pozisyon ile bir sonraki dalgadaki aynı pozisyonun aralarındaki mesafe iken, frekans ise belirli bir süre içerisinde aynı noktadan geçen dalga tepelerinin sayısıdır. 1 saniyedeki tepe sayısı 1 Hertz dir. Dalga boyu ile frekans arasındaki matematiksel ilişki Eşitlik 2.1'de gösterilmiştir. Işığın hızı c olmakla birlikte vakum içerisinde saniyede 300,000 kilometre (km)'lik sabit bir hıza sahiptir. Görünür ışık elektromanyetik spektrumun sadece küçük bir parçasını temsil eder (Khorram ve ark. 2012).



Şekil 2.4. Elektromanyetik Spektrum (Khorram ve ark. 2012)

Dalga boyu aralıkları yaklaşık 3.9×10^{-7} metreden (mor) 7.5×10^{-7} metreye (kırmızı) kadardır, ilişkili frekans aralıkları ise 7.9×10^{14} Hz'den 4×10^{14} Hz'e kadardır (Şekil 2.4). Elektromanyetik ışınım dalgaboyları çoğunlukla nanometre olarak ifade edilir.

Elektromanyetik ışınım madde ile temas ettiğinde, bu temas herhangi bir nesne ya da malzeme olabilir; ağaçlar, su veya atmosferik gazlar gibi, şu etkileşimler mümkündür:


- absorbe
- yansıma,
- saçılma
- madde tarafından elektromanyetik ışınım emisyonu veya madde boyunca elektromanyetik ışınım iletimi.

Uzaktan algılama öncelikli olarak yansıyan ve yayılan (EMR) tespit ve kayıt etme temeline dayanmaktadır. Temelde uzaktan algılamayı mümkün yapan, her nesne veya malzemenin belirli bir iletim ya da yansıtma özelliğine sahip olmasıdır (Khorram ve ark. 2012).

Bu durum müşterek olarak bilinen şekliyle nesnenin diğer nesnelere ya da nesnelere ayırt edilmesini sağlayan spektral imza ya da spektral profildir. Buna karşılık uzak algılayıcılar bu “spektral” verileri toplamak için oluşturulmuşlardır. Jensen (2005)’e göre uzaktan algılayıcılar bu verileri analog (örneğin hava fotoğraflarını uçağa monte edilmiş film kamerası ile toplayan) ya da daha yaygın olarak, dijital toplayabilir (Khorram ve ark. 2012).

2.1.5. Işınım (Radyasyon) Kanunları

Elektromanyetik enerjinin yayılması bazı kesin fiziksel yasalara göre olur. İlgili alanlarının özüne göre bu yasalar kısaltılmış şekilde özetlenebilir. Isaac Newton ışığın eş zamanlı olarak davranış gösteren birbiri ile ilişkili olarak her iki kesikli ve sürekli fenomen (olgu) olduğunu anlayıp ışığın ikili doğasının (ve bundan dolayı elektromanyetik ışınımın yani elektromanyetik radyasyonun tüm biçimlerinin farkına ilk varanların arasındadır. Newton ışığın minik parçacıkların deresi olduğunu ve düz çizgiler halinde seyahat ettiklerini iddia etmiştir. Bu görüş Max Planck (1858-1947) ve Albert Einstein (1879-1955)’nin modern teorileri ile tutarlıdır (Campbell ve Wynne 2011).



Şekil 2.5. “Boulevard du Temple, Paris”, 1838 yılında Louis Daguerre tarafından çekilmiş bir fotoğraf (Gümüşlü levha üzerine çekilmiş fotoğraf) (Khorram ve ark. 2012)

Planck elektromanyetik enerjinin adına kuantum ve foton denilen ayrı birimlerde emilme yayılmaya sahip olduğunu keşfetti. Buna göre her bir ünitenin büyüklüğü elektromanyetik ışınımın (radyasyonun) frekansı ile doğru orantılıdır. Planck sabit (h)'ın frekans (ν) ile ve ışınan enerji (Q) ile ilişkili olduğunu tanımladı:

$$Q = h\nu \quad (2.2)$$

Planck'ın modeli fotoelektrik etkisini açıklamaktadır, bazı maddelerin ışığa maruz kalması tarafından elektrik akımının üretimi, bazı metallerin yüzeylerindeki enerjinin (kuantum) bu ayrı birimlerdeki darbesinin etkisinde olduğu gibi elektronların salınımına sebep olurlar. Newton'nun prizmalar tarafından ışığın kırılmasını elektromanyetik enerjiyi dalga benzeri davranış göstererek seyahat etmesi varsayımı ile en iyi şekilde açıklamasındaki gibi başka bir olgu da bilmekteydi. James Clerk Maxwell elektromanyetik ışınımın dalga modelini resmi olarak ilk tanımlayan kişidir. Maxwell'in elektromanyetik enerjinin davranışlarının matematiksel tanımlamaları, klasik (mekanik) fizikteki ışık ve elektromanyetik enerjinin diğer biçimlerinin dalgalar dizisi gibi yayılmaları varsayımına dayanmaktadır. Kuantum teorisi diğer fenomenlerin (özellikle fotoelektrik etki) açıklamalarını sağlıyor ise de elektromanyetik enerjinin (örneğin lensler ve prizmalar ve dağılma tarafından kırılma) gözlemlenmiş davranışlarının bazı görüşlerini en iyi açıklayan dalga modelidir. Fotonların (kuantum) yüzeye çarpma açısı ışınım akış ya da radyant akış (radiant flux) olup Φ_c ile gösterilirse ve watt (W) cinsinden ölçülürse, bu ölçülen birim zamanda yüzeye iletilen enerjiyi belirtmektedir. Bu durumda birim alanı da belirtme gereksinimimiz vardır; parlaklık (E_c) her bir birim alandaki (genellikle her bir metre karede watt olarak ölçülür) ışınım akış ya da radyant akış (radiant flux) olarak tanımlanmıştır.

Parlaklık yüzeye çarpan ışınımı (radyasyonu) ölçerken ışımsal uyarıcılık (radiant exitance) M_c ile gösterilir ve birim alandan (aynı zamanda her bir metre karede watt olarak ölçülür) yayılan ışınım ya da radyasyon oranı olarak tanımlanır. Mutlak sıfırın üzerindeki sıcaklıklarda tüm nesnelere sıcaklığa sahiptir ve enerji yayarlar. Enerjinin miktarı ve yayılmadaki dalga boyları nesnenin sıcaklığına bağlıdır (Campbell ve Wynne 2011).

Nesnenin sıcaklığı arttıkça toplam enerjinin yayılımında artar. Böylece en fazla (zirve) yayılımının dalga boyu kısalır. Bu ilişkiler kara cisim kavramının biçimsel kullanımı için ifade edilebilir. Bir kara cisim ideal şekilde davranan enerjinin varsayımsal kaynağıdır. Gelen tüm ışınımı emer ve hiçbirini yansıtma. Bir kara cisim enerjiyi mükemmel verimlilik ile yayar; etkinliği sadece sıcaklık değiştiğinde enerjinin değiştiği bir radyatör gibidir. Kara cisim bir varsayımsal birimdir çünkü doğadaki tüm nesnelere kendilerine çarpan ışınımın (radyasyonun) küçük bir kısmını geri yansıtırlar böylece emilen enerjiyi geri yansıtma mükemmel davranmazlar. Tam anlamı ile mükemmel kara cisimler var olmasalar bile, onların davranışları laboratuvar aletleri kullanılarak kara cisime yaklaştırılabilir. Bu tür araçlar bilimsel araştırma için temel teşkil eden biçimde nesnelere sıcaklıkları ile aynı nesnelere yaymış oldukları ışınım (radyasyon) arasındaki ilişki olarak tanımlanır. Kirchoff'un kanunu yayılan ışınımın, emilen radyant akışa (radiant flux) oranı aynı sıcaklıklarda tüm kara cisimler için aynı olduğunu ifade eder. Bu yasa yayma oranının (ϵ) tanımı için temel biçimini oluşturur; belirli bir nesnenin (M) birim yüzeyden saniyedeki ışınım miktarı ve aynı sıcaklıktaki kara cisim (M_b) arasındaki oran:

$$\epsilon = \frac{M}{M_b} \quad (2.3)$$

Gerçek bir kara cismin yayım kabiliyeti 1 dir. Bunun yanında mükemmel yansıtıcının (bir beyaz cisim) yayım kabiliyeti 0 dır. Kara cisimler ve beyaz cisimler varsayımsal kavramlardır. Zorlu koşullar altında laboratuvarlarda varsayımsal değerlerine yaklaştırılmışlardır. Doğada, tüm nesnelere bu iki uç arasında yani siyah cisim ve beyaz cisim arasında salım gücüne sahiptir (gri cisim). Elektromanyetik enerjinin ışınımı gibi bu nesnelere etkinliğinin kullanışlı ölçüsü salım gücüdür. Bu nesnelere ışınımını yüksek oranlarda emme eğilimindedirler ve daha sonra tekrar ışınım yapan bu enerji yüksek salım gücüne sahip olacaktır. Enerjinin ışınımı ve emmesi gibi daha az etkiye sahip olanlar düşük salım gücüne sahiptir. Stefan-Boltzmann kanunu sıcaklık (T) ile toplam yayılmış ışınım (W) arasındaki ilişkiyi açıklamıştır (Campbell ve Wynne 2011) .

Toplam yayılmış ışınım genellikle watt.cm^{-2} olarak ifade edilir. Mutlak sıcaklık K olmak üzere :

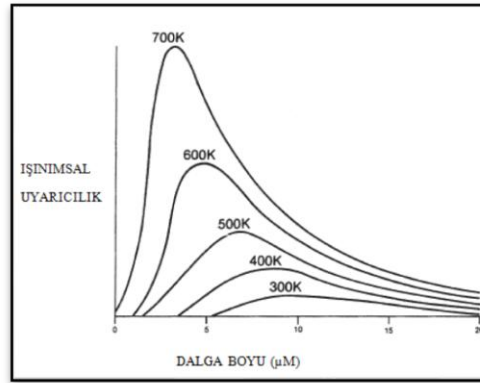
$$W = \sigma T^4 \quad (2.4)$$

Kara cisimden toplam ışınım yayılımı mutlak sıcaklığın dördüncü kuvveti ile orantılıdır. Sabit (σ) Stefan-Boltzmann sabiti olup ($5.6697 \times 10^{-8} \text{ watt.m}^{-2}.\text{K}^{-4}$) birim zaman ve birim alanı tanımlar. Aslında Stefan-Boltzmann yasası sıcak kara cisimlerden birim alanda yayıyan enerjinin soğuk siyah cisimlerden birim alanda yayılan enerjiden daha fazla olduğunu belirtmektedir. Wien'in yerdeğiştirme yasası ışınım yayılımının dalga boyu ile kara cismin sıcaklığı arasındaki ilişkiyi belirtir:

$$\lambda = 2.897.8/T \quad (2.5)$$

λ en fazla ışınım olduğu durumdaki dalga boyudur. T ise mutlak sıcaklıktır (K). Kara cisim sıcaklaştığında birim yüzeyden saniyedeki ışınım miktarının en fazla olduğundaki dalga boyu daha kısa dalga boylarına doğru yön değiştirir (Şekil 2.6).

Yukarıda anlatılan tüm ışınım kanunları elektromanyetik ışınımın (radyasyonun) anlaşılması için önemlidir. Bu üç ışınım kanunu kızılötesi spektrumda radyasyon tespiti tartışmalarında özel bir öneme sahiptir (Campbell ve Wynne 2011).



Şekil 2.6. Wien'nin yerdeğiştirme kanunu. Yüksek sıcaklıklarda kara cisimler için en fazla ışınım yayılımı kısa dalga boylarında oluşur. Düşük sıcaklıklardaki kara cisimler daha uzun dalga boylarında en fazla ışınım yayarlar (Campbell ve Wynne 2011)

2.1.6. Elektromanyetik Işınının Atmosfer İle Etkileşimi

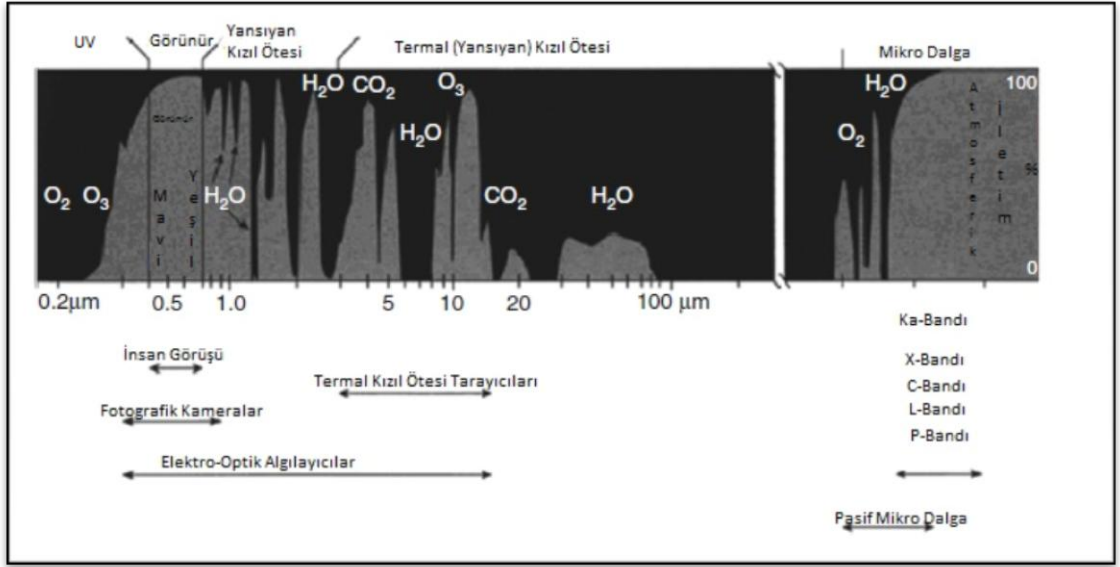
Uzaktan algılama için kullanılan elektromanyetik ışınım Dünya'nın yüzeyine ulaşmadan önce atmosferde seyahat etmek zorundadır. Parçacıklar ve gazlar gelen ışınımın özelliklerini değiştirebilirler. Bu değişimler atmosfer boyunca yolları üzerindeki fotonların saçılma ve emme durumlarından kaynaklanırlar. Saçılma, parçacıklar veya geniş gaz molekülleri atmosferde bulunduğu sırada elektromanyetik ışınım ile etkileşime girerek ve elektromanyetik ışınımı orijinal yolundan çıkartıp başka tarafa yönlendirdikleri zaman olur. Saçılımın ölçüsü birkaç faktöre bağlıdır. Işınımın dalga boyu, partikül ya da gazların bolluğu ve elektromanyetik ışınımın atmosfer boyunca olan yolcuğunun mesafesi bu faktörlere dahildir. Üç ana biçimde saçılım vardır. Elektromanyetik ışınım, ışığın dalga boyu ile karşılaştırıldığında küçük olan parçacıklar ile etkileşime girdiğinde Rayleigh saçılması oluşur. Toz ya da nitrojen ve oksijen moleküllerinin küçük lekeleri aydınlatıldığında bu saçılımı üretecektir. Kısa dalga boyları uzun dalga boylarına göre daha fazla saçılım yapmıştır. Atmosferin üst taraflarında saçılım mekanizması baskındır (Köhl ve ark. 2006).

Gündüz vakti gökyüzünün mavi gözükmesinin sebebi Rayleigh saçılımının doğrudan sonucudur. Gün ışığı atmosferi boydan boya geçerken, gözle görünür aralığın (spektrum) kısa dalga boylarının (mavi) saçılımı diğer dalga boylarından daha fazladır. Gün doğumu ve gün batımında ışık atmosfer boyunca öğlen zamanına göre daha uzun yol alır ve kısa dalga boylarının saçılması daha kapsamlı olur; daha uzun dalga boylarını daha büyük bir oranda bırakarak atmosfere nüfuz eder. Parçacıklar hemen hemen elektromanyetik ışınımın dalga boyu ile aynı büyüklükte olduğu zaman Mie saçılımı olur. Toz, polen, duman ve su buharı Rayleigh saçılımı ile etkilenenlerinkinden daha uzun dalga boylarını etkileme eğiliminde olup, Mie saçılımının yaygın nedenleridir. Mie saçılımı, çoğunlukla daha büyük parçacıkların daha yoğun olduğu atmosferin alt kısımlarında oluşur. Mie saçılımı bulutlu koşullarda baskın olur. Dalga boyundan daha geniş parçacıklar ile elektromanyetik ışınım çarpıştığında seçmesiz saçılım meydana gelir. Su damlacıkları ve büyük toz parçacıkları bu tür saçılıma neden olabilir. Seçmesiz saçılım, tüm dalga boylarında saçılımın yaklaşık eşit olması gerçeğinden dolayı bu ismi almıştır (Köhl ve ark. 2006).

Bu saçılım nedeni ile sis ve bulutlar beyaz olarak gözükmektedir; mavi, yeşil ve kırmızı ışığın hepsi yaklaşık olarak eşit miktarda saçılırlar (mavinin, yeşilin ve kırmızının toplamı beyaz ışığı verir). Emme ya da yutulma elektromanyetik ışınım atmosfer ile etkileşime girdiğinde iş başında olan başka bir ana süreçtir. Saçılımın aksine bu olaya çeşitli dalga boylarında enerjiyi atmosferde emen moleküller neden olur. Ozon, karbondioksit ve su buharı üç ana atmosferik emicilerdir. Ozon güneşten gelen zararlı (çoğu canlılar için) UV (ultraviyole) ışığını emer. Atmosferde ozon katmanı koruması olmaksızın güneş ışığına maruz kaldığında derimiz yanar. Karbondioksit spektrumun uzak kızılötesi (far-IR) bölgesinde etkin bir emicidir ve termal ısıtma ile ilişkilidir (Köhl ve ark. 2006).

Karbondioksit tarafından emilim aslında ısıyı tuzağa düşürmektir, eğer bu olmaz ise Dünya'nın atmosferi içinde kalmayıp, uzay boşluğuna yayılacaktır. Diğer sera gazları gibi bir sera gazı olan karbondioksit ısıyı yakalama özelliğindedir. Su buharı gelen uzun dalga kızılötesi (IR) ve kısa dalga mikro dalga ışınımı (22 m ve 1 nm arasında) atmosfer içinde emer. Alt atmosferdeki su buharının varlığı, konumdan konuma ve zamanla büyük ölçüde değişir. Çünkü bu gazlar spektrumun (elektromanyetik spektrum) çok özel bölgelerinde elektromanyetik enerjiyi emer. Ciddi bir şekilde atmosferik emilimden etkilenmeyen bölgeler, uzaktan algılama uygulamaları için en kullanışlıdır: Genellikle atmosferik pencereler olarak bilinirler (Şekil 2.7).

İki en yaygın enerji ya da ışınım kaynaklarının (Güneş ve Dünya) karakteristiklerini bize uygun mevcut atmosferik pencereleri ile karşılaştırarak, olası uzaktan algılama için en kullanışlı olması beklenen dalga boylarını tanımlayabiliriz. Spektrumun görünür kısmı güneşin en yoğun olan enerji seviyesi ve atmosferik pencerenin her ikisine de karşılık gelir. Dünya tarafından yayılan ısı enerjisi termal kızıl ötesi (thermal IR) bölgesinde 10 µm civarında bir pencereye karşılık gelir. 1 nm ötesindeki dalga boylarındaki geniş pencere mikrodalga bölgesi ile ilişkilidir (Köhl ve ark. 2006).



Şekil 2.7. Holton ve ark. (1995)'e göre elektromanyetik spektrum boyunca atmosferik pencere dağılımı. Her pencere için uygun algılayıcı tipi belirtilmiştir (Köhl ve ark. 2006)

2.1.7. Elektromanyetik Işınımın Yüzey İle Etkileşimi

Dünya'nın yüzeyine elektromanyetik enerji ulaştığında, bu enerji yansımak, emilmek ya da iletilmek zorundadır. Bu üç yola ait oranlar yüzeyin doğasına, enerjinin dalga boyuna ve aydınlatmanın açısına bağlı olan her bir işlem olarak değerlendirilmelidir.


Bir saydam olmayan yüzeye, ışık ışını çarpıp yeniden gönderildiğinde yansıma oluşur. Yansımanın doğası ışınım dikkate alındığındaki dalga boyu ile ilgili olarak düzensiz yüzeyin (pürüzlülük ve pürüzsüzlük) büyüklüğüne bağlıdır. Eğer yüzey, pürüzsüz ise, aynaya özgü olan yansıma oluşur (Şekil 2.8a). Aynaya özgü yansıma ya da aynasal yansıma (specular reflection) tek bir yönden gelen ışınım olayının her şeyi ya da hemen hemen herşeyini yansıtır. Bir çok yüzey için, geliş ve yansıma açıları birbirine eşittir:

$$n \sin \theta = n' \sin \theta' \quad (2.6)$$

Eşitlik 2.6'da bu nedenle iki ortam özdeşirler, böylece $n=n'$ ve bu nedenle $\theta=\theta'$ olur. Görünür ışınım için aynaya özgü ya da aynasal yansıma; ayna, pürüzsüz metal ya da dalgasız su birkintisi gibi yüzeylerde oluşabilir (Campbell ve Wynne 2011).

Eğer yüzey dalga boyu ile ilgili olarak pürüzlü ise, dağınık ya da yön bağımsız yansıtıcı gibi davranır. Enerji tüm yönlerde daha fazla ya da daha az eşitlikte olarak dağıtılır. Görünür ışınım için bir çok doğal yüzey dağınık yansıtıcı gibi davranabilir, örneğin tekdüze çimli yüzeyler bu karakterdedir. Mükemmel dağınık yansıtıcı (Lambertian yüzeyi olarak da bilinir) her açıdan gözlemlendiğinde eşit parlaklığa sahip olacaktır (Şekil 2.8b).

Mükemmel dağınık yansıma yüzeyinin ideal kavramı, ışığın davranışını tanımlamak için birçok deneyler tasarımı gerçekleştirmiş olan Johann H.Lambert'in (1728-1777) çalışmalarından elde edilmiştir (Campbell ve Wynne 2011).



(a)

(b)

Şekil 2.8. Aynaya özgü yansıtma (a) dağınık (b) yansıma. Aynasal yansıtma pürüzsüz yüzey ışınım olayını tek bir yöne yöneltme eğiliminde olduğu zaman olur. Dağınık yansıma pürüzlü yüzey enerjiyi tüm yönlerde daha fazla ya da daha az eşitlikte dağıtma eğiliminde olduğu zaman olur (Campbell ve Wynne 2011)

Lambert'in aydınlatma yasalarından bir tanesi bir mükemmel dağınık yüzeyin algılanan parlaklığı (ışınımı) görüş açısı ile değişmez demektir. Bu Lambert'in kosinüs kanunu, gözlemlenen parlaklığı (I), bu tür bir yüzeyin geliş açısının kosinüsü (Θ) ile orantılı, I sıfır sıklıkta gözlemlenmiş gibi ışınım olayının parlaklığı (Campbell ve Wynne 2011):


$$I' = I/\cos\Theta \quad (2.7)$$

Bu ilişki genellikle gözlemciden kaynağa kadar olan mesafenin karesine göre gözlenen parlaklık azaldığını belirten ters kare yasası ile eşit derece önemlidir (Campbell ve Wynne 2011):

$$I' = \left(\frac{I}{D^2}\right) (\cos\theta) \quad (2.8)$$

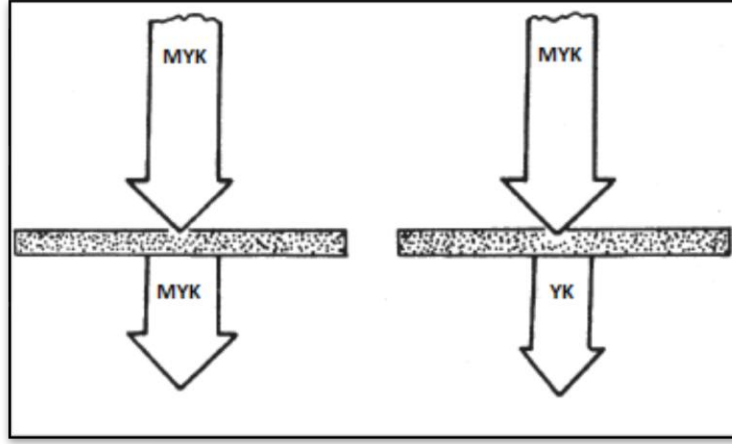
Her iki kosünüs yasası ve ters kare yasası (Şekil 2.9)'da açıklanmıştır. Işınım önemli bir zayıflama olmadan bir maddeden geçtiğinde ışınımın iletilmesi olur (Şekil 2.10). Bir maddenin verilen belirli bir kalınlık veya derinliği, enerji iletimi için ortamının becerisi, geçirgenlik olarak ölçülür (t):

$$t = \frac{\text{İletilen Işınım}}{\text{Işınım Olayı}} \quad (2.9)$$




Şekil 2.9. Ters kare yasası ve Lambert'in kosünüs yasası (Campbell ve Wynne 2011)

Uzaktan algılama alanında ışınım olayında, filmlerin ve filtrelerin geçirgenliği çoğu zaman önemlidir. Doğal olarak oluşan malzemeler ile ilgili olarak, sıklıkla sadece su birikintilerini, ışınımın önemli miktarda geçirilmesi kabiliyeti gibi düşünürüz. Buna rağmen, bir çok malzemenin iletimi dalga boyları ile büyük ölçüde değişir. Bu yüzden görünür spektrumdaki gözlemlerimiz spektrumun diğer parçalarına aktarma yapmaz. Örneğin, bitki yaprakları görünür ışınımında ışık geçirmez fakat kızıl ötesi ışınımında önemli miktarda iletim yapar (Campbell ve Wynne 2011).



Şekil 2.10. İletim, ışınım onayında önemli bir etki kaybı olmaksızın maddenin içinden geçer (sol), ya da seçici geçirgenlik olabilir (sağ). Sağ taraftaki nesne sarı (mavi eksilir) filtre gibi davranır. Tüm görünür ışınımı mavi ışık hariç iletir (Campbell ve Wynne 2011)

Emilme ışınım (enerji) hedef (cisim) tarafından emildiği zaman gerçekleşir (Şekil 2.11).



Şekil 2.11. Işınım ve madde arasındaki etkileşim (emilme) (Köhl ve ark. 2006)

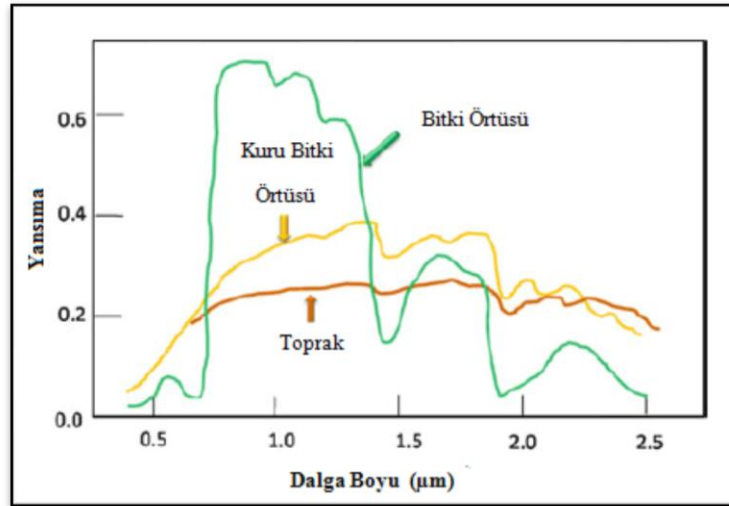
2.1.8. Spektral İmza

Uzaktan algılama teknolojileri uzak hedeflerdeki elektromanyetik enerjinin elde edilmesini ve ölçülmesini sağlayarak, Dünya'nın yeryüzündeki nesnelere ve sınıfların özellikleri hakkında bilgi çıkarılmasını sağlar. Mekansal coğrafi veriler hakkında yorumlamanın mümkün olmasının nedeni çeşitli malzemelerden elektromanyetik spektrumun değişik bölgelerinde farklı enerji miktarını yansıtması ya da yaylamasıdır (Lasaponara ve Masini 2012).

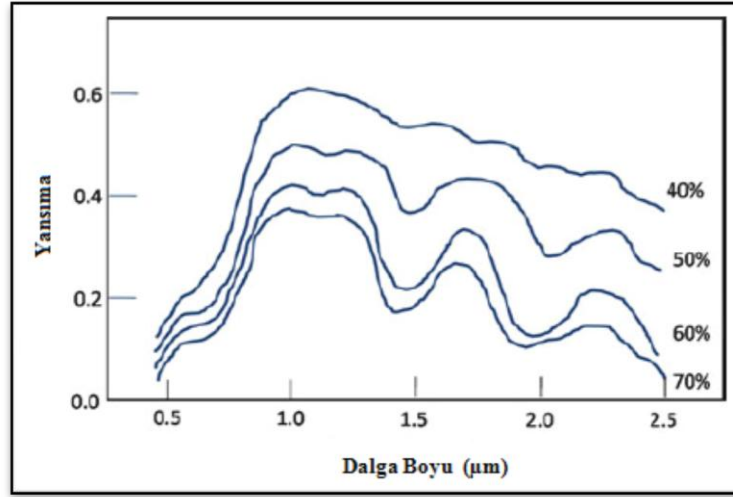
Çok bantlı görüntüler göz önüne alındığında, her bir piksel spektral değerler almıştır ve böylece pikseller çok boyutlu uzayda verilen görüntü bantıyla ilişkili eksenlere sahip çoklu mekansal görüntü uzayında bir vektör olarak temsil edilebilir. Böylece, spektral içeriği temelinde çeşitli yüzeylerde, (toprak, bitki örtüsü, deniz), malzemelerde (toprak tipleri, bitki örtüsü tipleri, beton) ve nesnelere (kentsel alanlar, arkeolojiksel özellikler) sınıflar veya türlerine göre, madde ve maddelerin spesifik karakteristiklerine (taze kar, bitki örtüsü tipleri, berrak su, nem içeriği, tane büyüklüğü) göre mekansal dağılımları tanımlayabilir ve kategorize edebiliriz. Karakteristiklerine göre çeşitli malzemeler için gözlemlenmiş farklı spektral yansımalar; genellikle spektral imzalar olarak bilinir.

Şekil 2.12 bitki örtüsü, toprak ve bitki örtülerinin farklı durumları için gözlemlenmiş spektral imzaların bazı örneklerini göstermektedir. Görünür spektral dalga aralığından (0.50 nm civarında) kısa dalga spektral dalga aralığına kadar (2.50 nm'ye kadar) bitki örtüsü ve toprağa kadar yeşil ve kuru bitki örtüsü çeşitli karakterize ve ayırımına olanak sağlayan spektral yansımalar göz önüne alınmalıdır. Şüphesiz Şekil 2.12 gözlem altındaki değişik hedefler için beklenen spektral yansımaları göstermektedir.

Açıkça gerçekte gözlemlenenler oldukça benzemelerine rağmen atmosferik kirlilik (bulut, havada asılı duran küçük parçacıklar gibi), görüş açısı, geometri gibi nedenlerden dolayı bazı farklılıklar vardır. Tüm ön işlem adımları kirlenme ve gürültüyü azaltmak ile ilgilendir (Lasaponara ve Masini 2012).



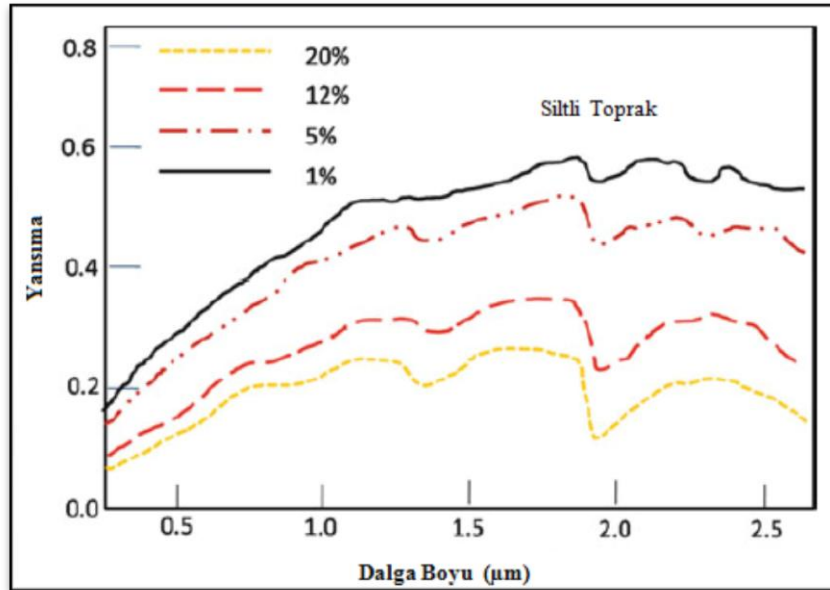
Şekil 2.12. Toprak ve bitki örtüsünün spektral imzaları (Lasaponara ve Masini 2012)



Şekil 2.13. Farklı nemlilik içeriklerine göre bitki örtüsü spektral imzalarının çeşitlilikleri (Lasaponara ve Masini 2012)

Şekil 2.13 farklı nemlilik içeriklerine göre bitki örtüsünün spektral yansımalarındaki çeşitlilikleri göstermektedir. Nemlilik içeriği arttığında suyun emilmesinden dolayı spektral yansıma genellikle azalma göstermektedir.

Şekil 2.14 siltli toprak içinde benzer davranışı gösterir, nemlilik gösterdiğinde spektral yansımada azalma olur (Lasaponara ve Masini 2012).



Şekil 2.14. Farklı nemlilik içeriklerine göre siltli toprak spektral imzalarının çeşitlilikleri (Lasaponara ve Masini 2012)

2.1.9. Dijital Görüntü Kavramı ve Piksel

Uzaktan algılama ve havadan arařtırmaların tarihinin bir çoęunda görüntüler fotoğraf ya da fotoğraf benzeri görüntüler olarak kayıt edilmiřtir. Bir fotoğrafik görüntü biçimi fiziksel kayıt, kimyasal kaplamalar ile bir parça kaęıt ya da film görüntünün örneklerini kayıt eder. Bir çok görüntü, analog görüntü olarak anılır çünkü bir fotoğrafın içindeki parlaklık, tüm sahne ya da manzara içerisindeki parlaklıkla orantılıdır ya da benzerdir.


Fotoğrafik araçlar görüntüleri kaydetmek için kalıcı değere sahip olmasına rağmen, uzaktan algılamanın içeriğinde depolamanın zorlukları, iletim, arama, ve analiz, gibi dezavantajlı olan durumlar vardır. Bu durumun tersine, dijital görüntü biçimleri, bir çok birbirinden ayrı değerleri diziler gibi piksel (resim elemanları) olarak bilinen bir görüntü meydana getiren görüntülerini temsil ederler. Görüntü kesikli sayıları temsil ettiğinde ilk zamanlardaki analog biçimler üzerinde bir çok avantaj sunarak kaliteli görüntü elde eder. Dijital değerler ilave edilebilir, çıkartılabilir, çarpılabilir ve genelde istatistiksel olarak ustaca yönetilebilir, fakat eęer görüntü sadece analog biçimde temsil edilirse bahsedilen işlemleri yapmak mümkün olmamaktadır. Dijital görüntülerin aynı zamanda sıkıştırılmış biçimde saklamak kolaydır ve kolay bir şekilde iletilir. Depolama ve geri alma ucuz ve etkilidir. Böylece dijital biçimi büyük ölçüde uzaktan algılanmış veriler için görüntüleme, inceleme, analiz etme yeteneęimizi artırır. Buna rağmen dijital biçimlerin kendi sınırlamaları olduęu her zaman geçerli olmadığına dikkat edilmelidir.

Görüntüler, sadece depolandıkları ortam kadar güvenli olabilirler, bu yüzden sadece analog görüntüler eskime ile bozulmaya, kötü kullanıma, fiziksel ortamdaki aşınmaya maruz kalırlarken, dijital veriler çürümeye, disk sürücülerindeki hasara, manyetik alanlara ve fiziksel ortamın bozulmasına maruz kalırlar. Dijital depolama ortamının biçimlerindeki eşit derece önemli deęişiklikler, dijital kopyalarını dijital ortamı okumak için gerekli donanımın demode olmasından dolayı erişilmez hale getirebilir. Dijital veriler Dünya'nın yüzeyininin parçalarını sistematik olarak tarayan araç gereçlerin ailesi tarafından oluşturulabilir. (Campbell ve Wynne 2011).

Bu şekilde yeryüzünün ayrı ayrı parçalarından yansıyan ya da yayılarak kayıt edilen fotonlar piksel olarak bilinir. Bir dijital görüntü binlerce pikselden oluşur. Genellikle her birisi insan gözü tarafından ayrı ayrı ayırt edilebilmesi için çok küçüktür. Her bir piksel yeryüzünün küçük bir bölgesinin parlaklığını temsil eder. Pikseller sayısal değer olarak genellikle elektromanyetik spektrumun birkaç bölgesinin her birisi için ayrı değerler ile dijital biçimde kayıt edilmişlerdir (Şekil 2.15).

Renkli görüntüler aynı yer gerçeğinin birkaç tür sırasının birleşiminden oluşmuştur. Bu sırada her bir temsil edilen parlaklıklar spektrumun farklı bölgelerindedir. Dijital görüntüler birkaç tür araç tarafından üretilebilir.

Tespit ediciler ışığa duyarlı içerikler, dakikada merceklerden gelen fotonları yakaladığında elektriksel akım üretir böylece parlaklık matrisi bir görüntü oluştururken, elektrik yüklerinin gücü odak düzlemine ulaşmış olur. Dijital hava kameralarındaki detektörler iki alternatif dizayn olarak uygulanır (Campbell ve Wynne 2011).



Şekil 2.15. Çoklu spektral pikseller (Campbell ve Wynne 2011)

2.1.10. Algılayıcılar

Hava fotoğrafçılığı, uydu görüntüleri ve radar uzaktan algılanmış verilerin tüm biçimleridir. Genellikle uzaktan algılanmış veriler uçakların ya da uyduların üstündeki algılayıcılardan (sensor) Dünya'ya ait toplanmış verilerdir. Uzaktan algılama platformlarındaki algılayıcılar genellikle elektromanyetik ışınımı kayıt ederler (Anonim, 1999).

(EMR) manyetik ve elektrik dalgalar biçiminde uzayda enerji iletirler (Anonim, 1999'den akt. Star ve Estes, 1990).

Uzaktan algılayıcılar elektromanyetik spektrumun özel dalga boylarını kayıt eden tespit edicilerden (detectors) oluşmuştur. Elektromanyetik spektrum elektromanyetik ışınımın kozmik dalgalarından radyo dalgalarına kadar uzanan aralıktır (Anonim, 1999'den ak. Jensen, 1996).

Yeni tip algılayıcılar hızlı bir şekilde gelişmişlerdir. Algılayıcılar biraz keyfi olarak bir ile on arasında veya ona yaklaşık olarak kanala bölünmüş iseler ve buna çoklu spektral ya da çoklu spektral ve algılayıcılarda on ile yüz arasında kanala bölünmüş spektral kanal olduğunda hiperspektral (hyperspectral) kanal olarak adlandırılırlar. Genellikle havadan taşınan ve uydu dizaynları birbirine karıştırılır. Bunun nedeni birçok yönden benzer özelliklerinin benzemeyen özelliklerinden fazla olmasındandır (Schott 2007).

Uzaktaki algılayıcıları değişik yollardan isimlendirebilir ve etiketleyebiliriz. Dünya gözlemlerimizdeki asıl ilgilimize göre belki; geometrik özellikler, spektral farklılıklar veya bir nesne ya da manzaranın yoğunluk dağılımı olabilir. Üç belirgin özelliğe göre algılayıcıları ayırt edebiliriz; altimetreler, spektrometreler, radyometreler. Lazer ve radar altimetreleri görüntü olmayan algılayıcılardır. Karaların ve suların yüzeyleri hakkında bilgi verirler.

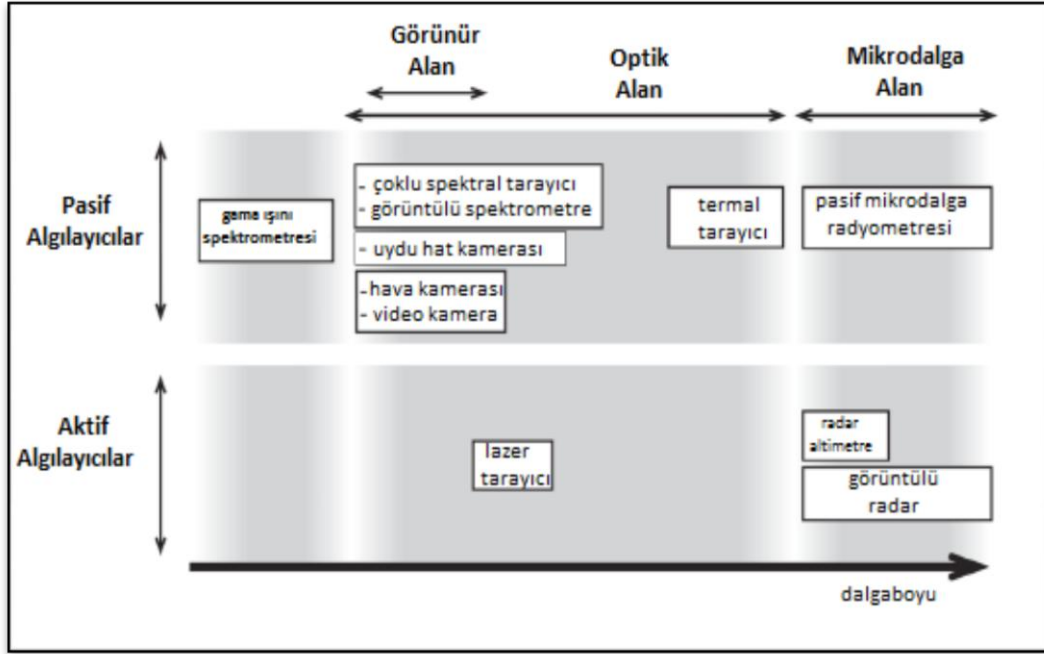
NOAA ve AVHRR'lerin üç ile beş arasındaki ya da Terra'nın ASTER'deki 10 ile 14 arasındaki kanala sahip termal algılayıcılar radyometreler (görüntüleme) olarak adlandırılırlar (Bakker ve ark. 2009).

Radyometreler tipik olarak bir geniş spektral bant içinde ya da sadece bir kaç bant ile fakat yüksek radyometrik çözünürlük ile ışınımı ölçerler. Pankromatik (bütün renklere hassas olan) kameralar ve pasif mikrodalga algılayıcıları diğer örneklerdir. Bu mekansal çözünürlük algılayıcısının dalga boyu bantına bağlıdır.

Pankromatik radyometreler çok yüksek mekansal çözünürlüğe sahip olurken, mikro dalga radyometreleri düşük mekansal çözünürlüğe sahip olabilirler. Bunun nedeni bu spektral aralıkta düşük enerji seviyesinde olmasıdır. Saçılım ölçer bir görüntüsüz radyometredir. Radyometreler geniş uygulama alanlarına sahiptirler. Orman tespit, çalılık arazi, kömür yangınları, topraktaki nemi belirlenmesi ve bitkilerin bu neme tepkisi, ekosistem dinamiğinin görüntülenmesi, kara ve deniz yüzeyleri boyunca enerji dengesinin analizi gibi konular radyometrelerin uygulama alanlarıdır.

Spektrometreler ışınımı bir çok (224'e kadar) dar ölçüm yaparlar, bu nedenle ardışık spektral bantlar yüksek spektral çözünürlüğe sahip olurlar. Mekansal çözünürlükleri ortadan düşüğe doğrudur. Spektrometre görüntülemenin asıl kullanımı toprağın mineral bileşiminden yüzey suyu ve klorofil asılı madde konsantrasyonuna kadar olan yüzeydeki maddeleri tanımlamaktır. Aynı zamanda her iki alandada olan (androgynies); spektrometreler, lazer taramalı görüntüleme, Fourier spektrometreleri gibi spektrometreler mevcuttur. Coğrafi mekansal verilerin kazanımı kullanımı için uzaktan algılayıcıları faaliyet gösterdikleri spektral etki ile ilgili olarak bir çok gruba konulabilir (Şekil 2.16).

Gama ışını spektrometrelerinin ana uygulamaları mineral keşiflerinde olmuştur. Hava film kameraları on yıllarca zor işlerde kullanılmıştır. Bugün ise ana kullanım alanları geniş ölçekli topografik haritalama, kadastro haritalama, kent planlaması için ortofoto üretilmesi gibi alanlardır. Dijital hava kameraları tüketici pazarında popüler olmadığı için dijital kameralar gibi çabuk bir şekilde pazara hakim olamamıştır. Dijital hava kameraları film yerine CCD sıraları kullanır ve optik tarayıcılar ile birlikte davranırlar. Hat kameralar uydulardan kumanda edilir ve çok benzer özelliklere sahiptirler. Dijital video kameraları hergün sadece hareketli resimleri kayıt etmek için kullanılmaz (Bakker ve ark. 2009).




Şekil 2.16. Algılayıcılara genel bakış (Bakker ve ark. 2009)


Aynı zamanda havadan dünya gözlemini düşük bir maliyet ile (ve düşük çözünürlük ile) ağırlıklı olarak nitel amaçlar için görüntüler elde etmek amacıyla kullanılırlar. Bu duruma havadan taşınan lazer tarayıcının kör kapsam alanına görsel bilgi sağlamak amacı örnek olarak verilebilir.

Çoklu spektral tarayıcılar çoğunlukla uydulardan ve diğer uzay araçlarından kumanda edilirler. Uydu hat kameraları ile aralarındaki temel fark görüntü ve optik sistemindedir: hatları taramak için hareket eden ayna kullanılırlar (yani yer üzerinde bir dar şerit) ve yoğunluk değerlerini tüm bir sıra olarak, bir anda, tespit ediciler sıra demeti tarafından kayıt edilmesi yerine, tek bir tespit edici tarafından kayıt edilir. Şekil 2.17'de Landsat TM kanalları 4, 5 ve 7 sırası ile kırmızı, yeşil ve mavi olarak gösterilmiş görüntüden birleştirilerek elde edilmiştir.

Hiperspektral tarayıcılar, tarayıcı aynalı görüntülü spektrometrelerdir. Termal tarayıcılar ise özel araçlar gibi ve bir çoklu spektral radyometrelerin bileşimi gibi varlığa sahiptirler. Termal tarayıcılar maddenin sıcaklığı ile doğrudan ilişkili olarak veri sağlarlar. Şekil 2.18'de gece uçuşu sırasında hava aracı termal tarayıcısı tarafından elde edilen bir termal görüntüye ait örnek göstermektedir (Bakker ve ark. 2009).



Şekil 2.17. 17 km'ye 20 km'lik bir alanda Landsat 5 TM sahte renk bileşimi (Bakker ve ark. 2009)



Şekil 2.18. Yer altında kömür yangınından etkilenen bir kömür madeni alanının termal görüntüsü. Koyu tonlar soğuk yüzeyleri gösterirken açık tonlar daha sıcak alanları gösterir. Göl olan geniş beyaz alan haricindeki sıcak noktaların çoğu kömür yangını nedeniyle oluşmuştur. Görünüşe göre gece vakti suyun sıcaklığı karanın sıcaklığından fazladır. Bu sıcaklık görüntüsü yaklaşık olarak 4 km genişliğindedir (Bakker ve ark. 2009)

Pasif mikrodalga radyometreler 10 ile 1.000 mm dalgaboyu aralığında Dünya'nın yüzeyinden yayılan ışınımı tespit ederler. Ana uygulamaları maden arama, topraktaki nem değişimini görüntüleme, kar ve buz tespitidir.


Lazer tarayıcılar lazer mesafe ölçerlerin ve lazer altimetrelerinin (ICESat ile ilgili olarak) değişik tarama biçimidir. Lazer tarayıcılar lazer cihazından hedefteki bir çok noktaya olan zamansız olarak (mesela bir saniyede 150.000) mesafeyi ölçer. Lazer mesafe tayin edici sık sık LIDAR (saniyedeki ışık tespit edici) olarak adlandırılır. Hava aracı ile taşınan lazer tarayıcının asıl uygulaması yüksek çözünürlüklü sayısal yüzey modelleri ve sayısal arazi modelleri oluşturmaktır. Sayısal arazi kabartma modeli (DTM) oluşturulabilir. Bu aynı zamanda

fotoğraflardan ve panoramik görüntülerden de elde edilebilir. Buna rağmen lazer ışınının özelliklerinden dolayı havadan taşınan lazer tarayıcısı yoğun bitki örtüsünün olduğu alanlarda, kum çöllerinde ve kıyı alanlarında önemli avantaja sahiptir. Yüzey modellemeleri bir çok uygulamalar ile ilgilenir. Orman biyokütle tahmini, açık maden ocaklarındaki hacim hesaplaması (Şekil 2.19) taşkınların haritalanması, şehirlerin 3D modellenmesi gibi örnekler verilebilir (Bakker ve ark. 2009).



Şekil 2.19. Hollanda, Sint Pietersberg’de bulunan açık maden ocağının sayısal yüzey modelinin resimli gösterimi. Ocak kabaca 1 km’ye 2 km boyutlarındadır. Ocağın terasının kenarı açıkça görünür biçimdedir. Görüntünün alt kısmının yakınındaki siyah şerit Maas nehridir. Rijkswaterstaat anket bölümünün müsadesi ile (Bakker ve ark. 2009)

Görüntülü radar (Radyo Tespit ve Mesafe Tayini) 10 ile 1.000mm arasındaki spektral alanda işlem yapar. Radar aletleri aktif algılayıcılardır çünkü dalgaboyu aralığında gündüz zamanı ve gece zamanı her türlü hava şartı altında verileri sağlarlar. Radar dalgaları bulutların içine nüfuz edebilir. Sadece aşırı yağmur yağışı olduğunda görüntüye az çok etki ederler. Bu duruma bağlı olarak radar uygulamalarından bir tanesi sürekli bulut kaplı yerlerin altındaki yerlerde harita oluşturmaktır. Şekil 2.20’de ERS-1 uydusundan SAR (Sentetik Açıklık Radarı) görüntüsünden bir örnek gösterilmektedir. Havadan ya da uzaydan elde edilen radar verileri aynı zamanda yüzey modelleri oluşturmak için kullanılır. Radar görüntüleme tuhaf bir geometriye sahiptir ve ham radar verilerini işlemek kolay değildir (Bakker ve ark. 2009).




Şekil 2.20. ERS-1 SAR görüntüsünün Kalimantan'da Mahakam deltası. Görüntü değişik tiplerde toprak örtüsünü göstermektedir. Nehirin kendisi siyahtır. Sol taraftaki koyu toprak parçası iç tropikal yağmur ormanlarıdır. Kalan yerler delta üzerindeki Nipa Palm ve Mangrove'nin karma ormanlarıdır. Resmin sağ yarısı ışıklı yamalar, parçalı parlak olarak ormanları göstermektedir. Görüntü 30km x 15km'lik alanı kaplamaktadır (Bakker ve ark. 2009)

Radar altimetreleri uydu yörüngelerine paralel Dünya'nın yüzeylerinin yükseklik profillerini ölçmek için kullanılırlar. Faaliyet gösterme aralıkları 10 ile 60 mm aralığındadır.


Sayısal yükseklik hesaplamaları için 20 ile 50 mm arasında kesinlik ile imkan sağlar. Radar altimetreleri nispeten pürüzsüz yüzeylerin ölçümleri için kullanışlıdır. Halen dört adet uzaydan taşınan radar altimetreleri kullanılmaktadır; Envisat bunlardan bir tanesini taşımaktadır. Şekil 2.21 ve Şekil 2.22 radar altimetre ürünleri için örnekler göstermektedir. Sonarın açılımı; değişen ses dolaşımıdır. Nehir yataklarının haritalanmasında, deniz tabanlarında, deniz altındaki engelleri tespit etme gibi durumlar için kullanılır. Gemiden küçük patlama sesinin yayılması ile çalışır. Ses su kütesinin altından yansır. Yansıyan darbe için gereken zaman, suyun derinliğine karşılık gelir. Daha gelişmiş sistemler aynı zamanda dönüş sinyalinin yoğunluğunu kayıt eder, böylece deniz tabanının üzerindeki maddeler hakkında bilgi vermiş olur. En basit şekliyle sonar aşağıya doğru bakar ve yapmış olduğu işlemler, radar altimetrenin yapmış olduğu

işlemlere çok benzer. Su kütlesi haritayı karelere bölme sisteminde olduğu gibi zikzaklı yollardan olacaktır. Su yüzeyinin altındaki her nokta görüntülenemeyecektir. Verilerin noktaları arasındaki mesafe, geminin hızına, mesafelerin sıklığına ve komşu yollar arasındaki mesafeye bağlıdır. Okyanusların tabanındaki geniş alanları görüntülemek için en doğru sistemlerden birisi yan taramalı sonar olarak adlandırılır (Bakker ve ark. 2009).



Şekil 2.21. Lazer altimetreler ve uzay bağlantılı radardan belirlenen deniz seviyesinin yüksekliği. Deniz seviyesinin ortalama deniz seviyesinin yukarısında belirlenmiştir. Texas Üniversitesinin müsadesi ile (Bakker ve ark. 2009)

Yan taramalı sonarlarında görüntüleme sisteminin çalışması, az çok yan bakan havadan taşınan radara benzer. Yan taramalı sonar sistemleri yüksek doğrulukla görüntü üretirler ve çok küçük nesnelere (1cm'den daha küçük) betimlemek için bile kullanılabilir. Sonar verilerinin kullanımı ile deniz tabanının ve diğer su kütlelerinin eş yükselti haritaları üretilebilir. Sonar verilerinin kullanımı ile ilgili uygulamalar gemi sefer ve su tahliyesi çalışmalarında bulunabilir (Bakker ve ark. 2009).



Şekil 2.22. Batı Hint okyanusunda, deniz tabanı kabartması. Deniz yüzünün uydu altimetresi tarafından ortaya çıkarılmıştır (GEOSAT). Okyanus ortası sırtlar ve dönüşüm faylarının her ikisinde yanlarıdır. Hindistan ve Madagaskar ve Hindistan arasındaki volkanik adalar zinciride gösterilmiştir. Görüntü kabaca 3800 km boyundadır (W.Smith ve D.Sandwell.1997'den akt.Bakker ve ark. 2009)

Günümüzde bir çok şirket ve ulusal hükümet, ekinler, ormanlar, su kütleleri, toprak kullanımı, şehirler ve mineraller gibi konularda Dünya'nın yüzeyini gözlemleyerek ilgili bilgiyi toplamak için özellikle dizayn edilen uzaktan algılama sistemlerini işletmektedir. Uydu algılayıcıları havadan taşınan platformların üzerinde bir takım avantajlar sağlamaktadır: Uydu algılayıcıları özet niteliğinde görüş sağlar (geniş alanın gözlemini bir tek görüntüde gösterirler), ince detay, sistematik ve tekrarlayan kapsamdadır. Dünya çapında kartografik alt yapı ve birçok geniş ölçekli dünyanın yüzyüze olduğu bir çok iki çevresel sorunlardaki değişikliklerin izlenmesini oluşturma ve koruma yetenekleri için uygundur. Kullanımda olan uydu gözlem sistemlerinin fazla sayılarında ve dizaynlarındaki hızlı değişimlerinden dolayı şu anda kullanımda olan ya da planlaması yapılan tüm sistemlerin tanımları ya da tüm listeleri yapılamamıştır. Fakat bu konuya ana hatları ile değinilebilir (Campbell ve Wynne 2011).

Bugünün arazi gözlem uyduları ilk sistemlerden gelişmiştir. Dünya'nın ilk gözlem uydusu, televizyon ve kızılötesi gözlem uydusu (TIROS), nisan 1960'da fırlatılmıştır. Bu seride ilk olarak bulut motiflerini izlemek için deneysel meteoroloji uyduları dizayn edilmiştir. TIROS Dünya'nın her tarafında günlük hava tahminleri için acilen meteorolojik veriler sağlayan kullanıma hazır programlar için ilk numuneydi. Orjinal TIROS uydu aracının arkasından gelenler, meteorolojik verileri elde etmek için tasarlanmış çeşitli programlarda uzun süre hizmet ettiler. Veriler meteorolojik uydulardan gelmesine rağmen, karasal kaynakları incelemek için kullanılmışlardır.

İlk meteorolojik algılayıcılar karasal kaynak gözlemleri için sınırlı kapasitelere sahipti. Algılayıcıları, bulut motiflerinin gözlemleri için değerli olmalarına rağmen, çoğu kaba mekansal çözünürlüğe sahipti. Böylece detaylı karasal kaynakları ile ilgili sadece tam gelişmemiş veriler sağlayabilmişlerdir. Landsat (kara uydusu) 1960'da özellikle Dünya'nın karasal alanlarının karasal kaynak çalışmalarını gerçekleştirmek için meteorolojik uydular meteoroloji ve klimatoloji (iklim bilimi) için başarılı olmuş geniş ölçekli gözlemleri için özel dizayn edilmiş ve 1972'de fırlatılmıştır.

Bugün Landsat sistemi Dünya kaynakları çalışmalarına katkıda bulunmuş bir uzaktan algılama sisteminde olduğu gibi hem kendi içinde ve hemde diğer organizasyonlar tarafından işletilen benzer karasal gözlem uydularını tanıtmak gibi öneme sahiptir (Campbell ve Wynne 2011).

Başlangıçta Landsat Dünya kaynaklarını teknolojisi uydusu (ERTS) olarak biliniyordu. İlk Landsat algılayıcıları enerjiyi yakın kızılötesi ve görünür spektrum bölgelerinde kayıt ediyorlardı. Spektrumun bu bölgeleri uçak fotoğrafçılığı için uzun süre kullanılmış olmasına rağmen, uydu irtifalarından Dünya kaynaklarının gözlemleri için, kesin pratiklik sağladıkları anlamına gelmiyordu. Bilim adamları ve mühendisler, bu algılayıcılardan planlandıkları gibi çalışacağından; güvenilir olduğunu ispat edeceğine, detayların tatmin ediciliğine ya da görüntülerin yeterli oranda bulut örtüsüz olacağı konularından tamamen emin değillerdi. Karşılaşılmış bir çok bu tip problemlere rağmen, basit kavramların uygulanabilirliği ispat edilmiş ve Landsat şu anda diğer organizasyonlar tarafından işletilen benzer sistemler için model olmuştur.

Landsat sistemi uzay gemisinden taşınan algılayıcılardan Dünya'nın gözlemlenmesinin ardından, veri kullanıcıları topluluğuna yayılması için, mikro dalga sinyalleri tarafından bilgilerin iletilmesi, yer istasyonlarında kabul edilmesi ve verilerin işlenmesinden meydana gelmiştir. İlk Landsat araçları iki algılayıcı sistemi taşımıştır: dönüş Işınlı Vidikon (RBV) ve çoklu spektral tarayıcı alt sistemi (MSS) Çizelge 2.1'de gösterilmiştir.

RBV, çoklu spektral tarayıcı alt sistemi (MSS) ile yakın, yüksek mekansal çözünürlük ve geometrik doğruluğa sahip fakat spektral ve geometrik detayları az olmasını sağlamak için tasarlanmış bir araca benzeyen bir kameraydı. Bu yüzden özelliklerin pozisyonları tam olarak gösterilmiş iken, renkleri ve parlaklıklarındaki ince detay endişesinden mahrumdur. Bu durumun aksine MSS'nin, pozisyonel doğruluğu az iken, Dünya'nın spektral karakteristikleri ile ilgili ince detay sağlamak üzere dizayn edilmiştir. RBV işlemlerini teknik zorlukların kısıtlamasından dolayı, MSS çok az bir süre sonra Landsat'ın ana algılayıcısı olmuştur (Campbell ve Wynne 2011).

Çizelge 2.1. Landsat görevleri (Campbell ve Wynne 2011)

Uydu	Fırlatma Tarihi	Hizmetin Sona Ermesi	Temel Algılayıcılar
Landsat 1	23 Temmuz 1972	6 Ocak 1978	MSS, RBV
Landsat 2	22 Ocak 1975	25 Ocak 1982	MSS, RBV
Landsat 3	5 Mart 1978	3 Mart 1983	MSS, RBV
Landsat 4	16 Temmuz 1982		TM, MSS
Landsat 5	1 Mart 1984		RM, MSS
Landsat 6	5 Ekim 1993	Fırlatma sırasında kaybedildi	ETM
Landsat 7	15 Nisan 1999		ETM +

Uydu sistemleri tipik bir şekilde resmi olarak hizmetten ayrılmadan önceki periyotlarda aralıklı ya da bekletilmesi temel alınması göz önünde alınarak işletilir. Landsat 4 için TM veri iletimi Ağustos 1993 tarihinde başarısız olmuştur. Landsat 7 için TM tarama hattı düzelticisinin arızası Mayıs 2003 tarihinden beri görüntülerin kalitesini sınırlamaktadır.

İkinci nesil Landsat araçlarına (Landsat 4 ve 5), MSS'in daha karmaşık bir uyarılama sürümü olan konulu harita (TM) ilave edilmiştir. Landsat'ların şimdiki

ailesi, konulu haritanın gelişmiş bir uyarlama sürümü olan ETM+ taşımaktadır (Campbell ve Wynne 2011).

TM, hassas mekansal çözünürlük, gelişmiş geometrik doğruluk, daha fazla geometrik detay ve daha fazla detaylı spektral bilgi ve daha kesin olarak spektral bölgelerin tanımlanmasını sağlar. Gelişmiş uydu kararlılığı ve ayarlanmış yörünge alt sistemi (OAS) pozisyonel ve geometrik doğruluğu arttırmak için tasarlanmıştır. Landsat araçlarının ikinci nesil hedefleri, MSS verilerinin sürekli kullanılabilirliğini sağlamak ve yabancı veri alımına devam etmek için TM performanslarını değerlendirmektir. MSS ve TM aralarındaki tarihsel ilişkiye rağmen, TM'nin iki algılayıcısı farklıdır. MSS dört geniş tanımlı spektral bölgeleri kayıt ederken, TM yedi spektral bantları kayıt eder. Çizelge 2.2' de bu bantların karakteristikleri özetlenmiş olup belirtilen liste tüm uygulamaları değil bazılarını içerir.

TM bant atamaları spektral tanımlamaların birbirini takip eden sırayı izlememektedir. En uzun dalga boylu bant 6 olup bant 7 yerine geçmiştir. Bunun nedeni bant 7'nin ilave edilmesi oldukça gecikmesi yüzündendir. Dizayn işleminde mantıklı bir sırayı takip etmek ve bantları tekrar etiketlemek mümkün olmamıştır. TM bantlarının birkaç kombinasyonu genel kullanım amaçları için etkili görünmektedir. TM bantlarından 2, 3 ve 4 kullanılarak oluşturulan görüntüler her zamanki sahte renk hava fotoğraflarına benzer. TM bantları 1 (mavi yeşil), 2 (yeşil) ve 3 (kırmızı) biçimleri doğal renk bileşimi, yaklaşık olarak hava fotoğraflarının içindeki temsil edilen renklerine eşdeğerdir. Diğer kombinasyonlar ile yapılan deneyler göstermiştir ki, bant 2, 4 ve 5; bant 2, 4 ve 7; ve bant 3, 4 ve 5 aynı zamanda görsel yorumlama için etkilidirler. Elbette, özel şartlarda kullanılması için TM'nin yedi bantının diğer bir çok kombinasyonları vardır (Campbell ve Wynne 2011).

Çizelge 2.2. TM algılayıcı karakteristiklerinin özeti (Campbell ve Wynne 2011)

Bant	Çözünürlük	Spektral Tanım	Bazı Uygulamalar
1	30 m	Mavi-Yeşil, 0.45-0.52 μm	Temiz suya nüfus etme; batimetri, kıyı sularını haritalama, klorofil absorpsiyon; iğne yapraklı ve yaprak dökken bitki örtüsü arasındaki ayırım
2	30 m	Yeşil, 0.52-0.60 μm	Sağlıklı bitki örtüsünden yansıyan yeşil ışınımı kayıt eder. Bitki canlılığını değerlendirir. Bulanık sudan gelen yansımalar
3	30 m	Kırmızı, 0.63-0.69 μm	Bitki tipleri ayırımı için klorofil absorpsiyon önemi
4	30 m	Yakın kızılötesi, 0.76-0.90 μm	Bitki hücre yapısının belirlenmesi; biokütle Bitki canlılığı, su tarafından tam emilim kıyı sınırlarının çizilmesini kolaylaştırır.
5	30 m	Orta kızılötesi, 1.55-1.75 μm	Bitki örtüsünün nem içeriğinin gösterilmesi; Toprak nem haritalama; bulutlardan kar ayırt etme; ince bulutların içine işleme
6	120 m	Uzak kızılötesi, 10.4-12.5 μm	Bitki örtüsü stres analizi; toprak nem ayırımı; termal haritalama; göreceli sıcaklık parlaklığı; toprak nemi; bitki ısı stresi
7	30 m	Orta kızılötesi, 2.08-2.35 μm	Kaya tiplerinin ayırımı; ayrışma bölgeleri için hidrotermal haritalama; hidroksi iyon emilim

2.1.11. Uzaktan Algılamada Çözünürlük Kavramı

Aktif ya da pasif, hangi uzaktan algılama sistemi olursa olsun, tüm uzaktan algılama sistemleri Dünya'nın yüzey özelliklerinden ya da atmosferden gelen sinyalleri yani enerjiyi tespit ve kayıt eder. Havadan taşınan kameraların ve video kayıtlarında dahil olduğu uzaktan algılama sistemlerinde benzer örnekler vardır. Elektronik tarayıcılar, doğrusal bölge sıra tarayıcıları, lazer tarayıcı sistemleri ve buna benzer örneklerin dahil olduğu daha fazla karmaşık algılama sistemleri verileri analog biçimde ya da dijital biçimde olmak üzere her iki sistemde verileri toplar. Analog biçime örnek olarak hava fotoğrafçılığı sabit kopya ya da video verileri verilebilirken, dijital biçime örnek olarak ise parlaklık değerleri ile ilişkili görüntüdeki piksel içinde ölçülen ortalama ışınım verilebilir. Jensen, (2005)'e göre uzaktan algılanmış görüntülerden verilerin toplanmasının başarısı, isimleri ile dört temel; mekansal, spektral, radyometrik ve zamansal olan çözümleme karakteristiklerinin anlaşılmasını gerektirmektedir (Weng 2010).

Görüntü aygıtı üzerinde görüntüleyebildiğiniz piksel sayısı ya da görüntü dosyasının içindeki pikselin temsil ettiği yer üzerindeki alan tanımlamaları çözünürlüğün yaygın olarak çoğunlukla kullanılan tanımlarıdır. Bu geniş tanımlamalar uzaktan algılanmış verileri tanımlarken yetersiz kalırlar. Dört ayrı çözünürlük biçimleri dikkate alınmalıdır (Anonim, 1999).

2.1.11.1. Spektral Çözünürlük

Spektral çözünürlük, algılayıcının kayıt edebildiği elektromanyetik spektrum içerisindeki belirli dalga boyu aralıklarını kasteder (Simonett 198'den akt. Anonim, 1999). Her bir uzaktan algılayıcı algıladığı elektromanyetik spektrumun parçası ile ilgili özgündür. Değişik uzaktan algılama araçları elektromanyetik spektrumun değişik bölümlerini veya bantlarını kayıt eder.

Bir algılayıcının spektral çözünürlüğü kayıt edebilen bantların büyüklüğü ve sayısını kasteder (Jensen, 2005'den akt. Weng 2010).

Örneğin Landsat TM (konulu harita) algılayıcısının 1. bantı 0.45 μm ile 0.52 μm arasındaki spektrumun görünür parçasındaki enerjiyi kayıt eder. Elektromanyetik spektrumun geniş aralıklarına kaba spektral çözünürlük olarak

kastedilirken, dar aralıkları ince spektral çözünürlük olarak kastedilir. Örneğin SPOT pankromatik algılayıcısı kaba spektral çözünürlüğe sahip olarak düşünülmüştür. Bunun nedeni elektromanyetik ışınımı 0.51 μm ile 0.73 μm arasında kayıt etmesindedir. Diğer taraftan Landsat TM algılayıcısının 3. bantı ince spektral çözünürlüğe sahiptir. Bunun nedeni elektromanyetik ışınımı 0.63 μm ile 0.69 μm arasında kayıt etmesindedir. Spektral çözünürlük kaç tane sinyalin giriş yaptığını göstermez (Anonim, 1999).

AVHRR (Gelişmiş çok yüksek çözünürlüklü radyometre), yerleşik Amerikan ulusal osinografik ve atmosferik uygulamanın (NOAAs) kutupsal yörüngeli çevresel uydusu (POES) platform dört ya da beş geniş spektral bant bir araya getirmiştir (birbirinden ayrı araçlara bağlı olarak). Görünür (0.58-0.68 μm), yakın kızılötesi (0.725-1.1 μm), orta kızılötesi (3.55-3.93 μm) ve elektromanyetik spektrumun (10.3-11.3 μm ve 11.5-12.5 μm) termal (ısı) kızılötesi bölümlerindedir. Landsat TM algılayıcıları 7 spektral bantları bir araya getirir. Sırasıyla: Mavi (0.45-0.52 μm), Yeşil (0.52-0.60 μm), Kırmızı (0.63-0.69 μm), Yakın kızılötesi (0.76-0.90 μm), Kısa kızılötesi (1.55-1.75 μm), Termal kızılötesi (10.4-12.5 μm), Kısa kızılötesi (2.08-2.35 μm). Landsat TM algılayıcılarının spektral çözünürlükleri çoklu spektral tarayıcı (MSS) ve dönüş ışınli vidikon (RBV) gibi ilk uçaktan taşınan modellerdeki Landsat araçlarından daha yüksektir. Hiperspektral algılayıcılar (görüntülü spektrometreler) spektrumun görünür, yakın kızılötesi, orta kızılötesi ve termal kızılötesi kısımlarında bir çok, oldukça dar bitişik spektral bantlardan görüntü elde eden araçlardır (Weng 2010) .

Oysa Landsat TM, 0.27 μm genişliğinde, bir hiperspektral algılayıcı üzerine entegre cevap gelen sadece bir veri noktası elde eder. Örneğin 0.01 μm genişliği civarında bantları kullanarak, bu aralıkta bir çok veri noktalarını elde etme yeteneğine sahiptir. Amerikan ulusal havacılık ve uzay dairesine (NASA) ait havadan taşınan görünür ya da kızılötesi görüntü spektrometresi (AVIRIS) dalga boyları 400 ile 2500 nm aralığında 224 bitişik bantlardan gelen verileri toplar. Bir geniş bant sistemi sadece malzeme tipleri arasındaki genel farklılıkları ayırt edebilir. Oysa hiperspektral algılayıcının malzemelerin potansiyel detaylı tanımlamalarına ve miktarlarının en iyi tahminlerini yapmaya gücü yeter. Hiperspektral algılayıcıya diğer bir örnek MODIS'dir. NASA'nın her iki Terra ve

Aqua görevlerinde, kara okyanus ve eş zamanlı atmosferik işlemler hakkında kapsamlı verileri ara vermeden sağlamaktadır (Weng 2010).

2.1.11.2. Mekansal Çözünürlük

Mekansal çözünürlük uzaktan algılamada veri toplamak için kullanılan herhangi görüntü sisteminin temel özelliğidir ve meydana gelen bilginin mekansal ölçeğini direkt olarak belirler. Çözünürlük sezgisel olarak açıkça görünmektedir (Robinson ve ark. 2002).

Fakat çözünürlüğün teknik tanımı ve uzaktan algılamadaki hassas uygulaması karmaşık olmuştur. Örneğin Townshend (1980) Landsat çoklu spektral tarayıcı (MSS) 'nin çözme gücünün tahmini için 13 farklı yol özetlemiştir (Robinson ve ark. 2002). En basit durumda mekansal çözünürlük bir algılayıcının iki nesne arasındaki en az uzaklıkta açıkça kayıt edebilmesi gibi tanımlanabilir (Simonett, 1983'den akt. Robinson ve ark. 2002). Fakat algılayıcı sisteminin biçimi mekansal çözünürlüğün nasıl ölçüldüğünü belirler. Sistemin özelliklerine dikkatle odaklanıldığında bu tanım farklı sistemler tarafından sağlanan çeşitli görüntü tiplerine uygulanabilir. Mümkün olduğunca eksiksiz bir işleyiş sağlamak için, ilgili astronot fotoğrafçılığın mekansal çözünürlüğü dikkate alındığında, arka plan mekansal çözünürlüğü çeşitli görünümelerde sağlanır (Robinson ve ark. 2002).


Mekansal çözünürlüğüne geometrik çözünürlükte denilir. Mekansal çözünürlük yüzey birimi başına piksel sayısıdır (Köhl ve ark. 2006).

Uzaktan algılamada, mekansal çözünürlük karada gerçek boyut açısından ifade edilir ve metrenin ISO birimlerinde ifade edilir (Köhl ve ark. 2006), (Şekil 2.23). Mekansal çözünürlük algılayıcı tarafından çözümlenebilir en küçük nesnenin ölçüsü ya da her bir piksel tarafından yer üzerinde temsil edilen alandır (Simonett, 1983'den akt. Anonim, 1999).

En iyi mekansal çözünürlük, en düşük sayıya sahiptir. Örneğin, 79 metre mekansal çözünürlük 10 metre mekansal çözünürlükten daha kabardır. Büyük ölçekli görüntüler ve küçük ölçekli görüntü terimleri sıkça mekansal çözünürlük olarak adlandırılırlar. Ölçek harita üzerindeki mesafenin ilişkili olduğu yer üzerindeki gerçek mesafeye olan oranıdır (Star ve Estes, 1990'den akt. Anonim, 1999). Uzaktan algılamada büyük ölçek, görüntüdeki her bir pikselin

yeryüzündeki küçük bir alanı temsil ettiğini ifade eder. SPOT uydusunun verilerinde olduğu gibi mekansal çözünürlüğü 10 m. ya da 20 m.'dir. Küçük ölçek, görüntüdeki her bir pikselin yeryüzündeki büyük bir alanı temsil ettiğini ifade eder. AVHRR'de olduğu gibi mekansal çözünürlük 1.1 km'dir (Anonim, 1999). Bu terminoloji 1:50.000'de olduğu gibi haritanın ölçeğini temsil etmek için kullanılan kesirden türetilmiştir. Küçük ölçekli görüntü küçük bir kesir ile temsil edilir ve (bir bölü çok büyük sayı) büyük ölçekli görüntü büyük bir kesir ile temsil edilir (bir bölü küçük bir sayı) (Simonett, 1983'den akt.Anonim, 1999).

Genellikle, 1:250.000'den küçük herhangi bir ölçek küçük ölçekli görüntü olarak düşünülür (Anonim, 1999). Ölçek ve mekansal çözünürlük her zaman aynı şeyler değildir. Bir görüntü her zaman aynı mekansal çözünürlüğe sahiptir, fakat aynı görüntü farklı ölçeklerde temsil edilebilir (Simonett, 1983'den akt.Anonim, 1999).



Şekil 2.23. Üç farklı mekansal çözünürlükteki görüntülerin arasındaki karşılaştırma.

a SPOT (10 m); b OrbView-1 (3 m); c OrbView-1 (1 m) (Köhl ve ark. 2006)


2.1.11.3. Radyometrik Çözünürlük

Radyometrik çözünürlük gelen ışınımın bir algılayıcının bir değişiklik gerçekleşmeden önce kaydedilen parlaklık değerinin, ışınımdaki ne kadarlık değişiklikle algılayıcıda ne kadar değişikliğe yol açması gerektirdiği durumundaki hassasiyeti olarak ifade edilir (Jensen, 2005'den akt. Weng 2010). Kaba radyometrik çözünürlük sadece bir kaç parlaklık düzeyini kullanarak bir görünümü kayıt eder. Oysa, çok fazla kontrast (görüntüdeki karışıklık) durumda iken ince radyometrik çözünürlük, aynı görünümü bir çok parlaklık seviyesini kullanarak kayıt eder (Köhl ve ark. 2006).

Örneğin Landsat-1 çoklu spektral tarayıcı (MSS) başlangıçta 6 bit ışınım enerjisini kayıt eder (değerlerin değişimi 0'dan 63'e kadardır). Daha sonra kayıt edilebilen ışınım enerjisi 7 bit'e genişletilmiştir (değerlerin değişimi 0'dan 127'ye kadardır). Tersine, Landsat TM verileri 8 bit'de kayıt yapar; yani parlaklık seviyeleri 0'dan 255'e kadar değişir (Weng 2010). Radyometrik çözünürlük, elektromanyetik spektrumun aynı bölgesinde, izlenmiş nesnelere arasında en iyi ayrımı yapabilmeyi sağlar. Sayısal rakam değerleri, görüntü verilerini tarafından gösterilir ve 0'dan 2'nin seçilmiş kuvvetine kadar değişir. Aralık, ikili biçimde kod numaraları için kullanılan bit'lerin sayıları ile ilişkilidir. Her bir bit 2'nin üstel kuvveti olarak kayıt eder. Mevcut parlaklık seviyelerinin en büyük sayısı kullanılan bit'lerin sayısına bağlıdır. Eğer algılayıcı verileri kaydetmek için 8 bit kullanıyor ise, $2^8=256$ seviye ya da değer olmalıdır (Köhl ve ark. 2006).

Radyometrik çözünürlük ile kaydedilen dinamik aralık ya da her bir bantta olası veri dosyalarının değerlerinin sayısıdır. Bu kayıt elde edilen enerjinin bölüdüğü bit sayısına göre adlandırılır. Örneğin, 8 bit verilerde, her bir piksel için verilerin dosya değerleri aralığı 0'dan 255'e kadar iken, 7 bit verilerde, her bir piksel için verilerin dosya değerleri 0'dan 128'e kadardır.

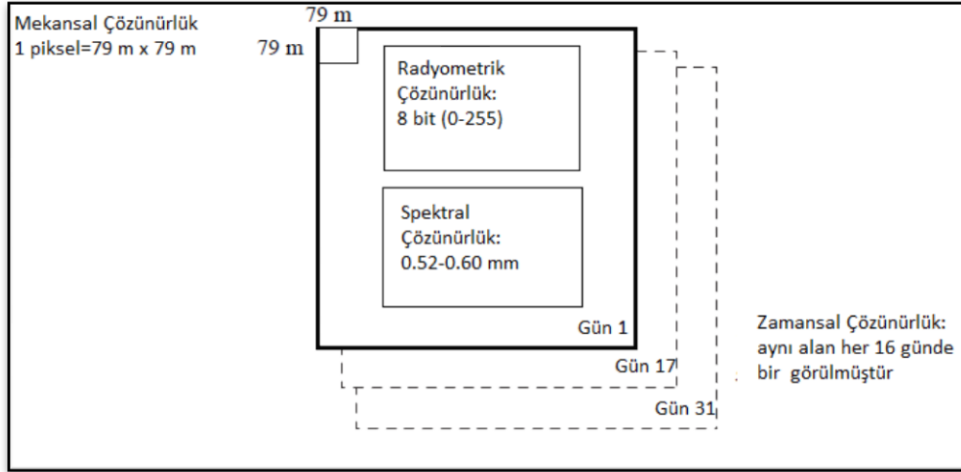
Şekil 2.24'de 8 bit ve 7 bit veriler resimlendirilmiştir. Algılayıcılar elektromanyetik ışınımı (EMR) kendi aralığında ölçerler. Enerjinin toplam şiddeti 0'dan algılayıcının en fazla miktarda ölçen 8 bitlik veri için 256 parlaklık değerine bölünür. Bu durum 7 bitlik veri için 128 parlaklık değerine bölünür (Anonim, 1999).



Şekil 2.24. Parlaklık değerleri (Anonim, 1999)

2.1.11.4. Zamansal Çözünürlük

Belirli bir alanın, bir algılayıcı tarafından hangi sıklıkla görüntü elde etmiş olduğu, zamansal çözünürlük olarak ifade edilir (Anonim, 1999). Başka bir tanım olarak; zamansal çözünürlük, bir algılayıcının daha önce görüntülendiği konuma dönmek için geçen zamanın süresi olarak ifade edilir. Bundan dolayı, zamansal çözünürlük değişim tespiti ve çevresel izlemede önemli saklı bir anlama sahiptir. Bitki örtüsü, hava durumu, orman, yangın, volkanlar gibi bir çok çevresel olgular zaman içerisinde sürekli değişiklik gösterirler. Zamansal çözünürlük bitki örtüsünün uzaktan algılamasında önemli bir husustur çünkü bitki örtüsü güne göre, mevsime göre ve yıllık fenolojik (bitki ve hayvan etkinliklerinde iklimin yıllık olgular üzerine etkisinin çalışılması) döngüye göre gelişir. Anlatılan yıl dönümde ya da yıldönümünün yakınlarındaki tarihlerde bitki örtüsünün değişimini tespit eden görüntüleri elde etmek çok önemlidir. Yıl dönümü görüntüleri mevsimsel farklılıkların etkisini büyük ölçüde en aza indirir (Jensen, 2005'den akt.Weng 2010). Bir çok hava durumu algılayıcıları yüksek zamansal çözünürlüğe sahiptir: Geosensat operasyonel çevresel uydu (GOES), 0.5/saat; NOAA-9 AVHRR yerel-alan kapsama, 14.5/gün; ve ilk nesil Meteosat, her 30 dakikadır (Weng 2010). Landsat görevinde örneğin, tekrar ziyaret zamanı 16 gündür. Orjinal ismi ile Système Pour l'Observation de la Terre yani SPOT uydusunun dördüncü numaralı olanın görevi 26 gün ve OrbView 3 gündür (Köhl ve ark. 2006). Şekil 2.25'de tüm dört tip çözünürlük gösterilmiştir.



Şekil 2.25. Landsat TM-Band 2, dört tip çözünürlük, kaynak EOSAT (Anonim, 1999)

2.2 . İstatistiksel Öğrenme Kavramı

İstatistik alanı, bilim ve endüstrinin kendi kapılarından getirmiş olduğu problemlere sıkça meydan okumuştur. İlk günlerde bu problemler tarımsal ve endüstriyel deneylerden sıklıkla nispeten küçük kapsamdan gelmekteydi. Bilgisayarların gelmesi ile birlikte bilgi çağı, istatistiksel problemlerin büyüklüğü ve karmaşıklığındaki patlamayı beraberinde getirdi. Veri depolama, organizasyon ve arama alanlarındaki zorluklar veri madenciliği isminde yeni bir alanın oluşmasına yol açtı. Biyoloji ve tıp alanlarındaki istatistiksel ve hesaplamalı problemler biyoinformatiği oluşturdu. Bir çok alanda üretilen büyük miktarda veriler için istatistikçilerin işi önemli modeller ve eğilimler çıkartmak ve verilerin ne söylediklerini anlayarak hepsini mantıklı yapmaktır. Bu durum verilerden öğrenmek olarak adlandırılır.

Verileri öğrenme zorlukları istatistiksel bilimlerde devrim olmasına yol açmıştır. Hesaplamalar anahtar bir rol oynadığı için, bilgisayar bilimleri ve mühendislik gibi diğer alanlardaki araştırmacılar tarafından bu yeni gelişmelerin çoğunun tamamlanmış olması süpriz değildir.

Öğrenme problemleri ön bilgilendirmeli (supervised) ya da ön bilgilendirmesiz (unsupervised) olarak kabaca kategorize edilebilir. Ön bilgilendirmeli öğrenmede, girdi ölçütü sayısını temel alan sonucun tahmin değeri amaçtır. Ön bilgilendirmesiz öğrenmede ise, giriş ölçütü yoktur ve amacı, ilişkileri ve girdi ölçütlerinin kümesinden modelleri tanımlamaktır. İstatistiğin alanı

dışındaki araştırmacılardan bir çok şey öğrenilebildiği gibi, istatistikçilerin bakış açısı öğrenmenin farklı yönlerini anlamak için başka alanlardakilere yardımcı olabilir (Hestie ve ark. 2008).

Hiçbir şeyin gerçek yorumlaması yoktur; yorumlama, insanın kavrama hizmetindeki bir araçtır. Yorumlamanın değeri, bir fikir hakkında diğerlerinin verimli bir şekilde düşünmesini sağlamaktır (Andreas Buja'dan akt. Hestie ve ark. 2008).

2.2.1. İstatistiksel Öğrenmenin Kullanım Alanları

İstatistiksel öğrenme bilimin, finansın ve endüstrinin bir çok alanında anahtar rol oynar. Öğrenme problemlerine bazı örnekler aşağıda verilmiştir:

- Hasta olup olunmamasının tahmin edilmesi; kalp krizi nedeniyle hastaneye yatırılması, gelecekte ikinci kalp krizi olması ihtimalinde ilgili hasta için, tahmin demografik, diyet ve kliniksel ölçüler temel alınır.
- Şimdiden 6 ay içindeki stok fiyatlarının tahmini, firmanın ekonomik verilerine ve performans ölçülerinin temeline dayanır.
- El yazısı posta kodlarının numara tanımlamaları bir rakamsallaştırılmış görüntüdür.
- Bir diyabet hastasının kanındaki glikoz miktarının tahmini, hastanın kanındaki kıızılötesi emilme spektrumundan yapılır.
- Prostat kanseri için risk faktörlerinin tanımlamaları, kliniksel ve demografik değişkenlere dayanılarak yapılır.

Öğrenme bilimi istatistik, veri madenciliği ve yapay zeka, mühendislik ve diğer disiplin alanları ile kesişen alanında bir anahtar rol oynar. Çizelge 2.3'de verilen örnekte ön bilgilendirmeli öğrenme olarak adlandırılan problemin tanımı yapılmıştır. Ön bilgilendirmeli olarak isimlendirilmesinin sebebi sonuç değişkeninin öğrenme sürecine rehberlik etmesidir. Çizelge 2.3'deki örnek 4601 eposta mesajlarındaki bilgilerden oluşmaktadır. Bu çalışmada eposta'nın önemsiz eposta ya da spam olup olmadığının tahmini yapılmaya çalışılmıştır (Hestie ve ark. 2008).

Çizelge 2.3. e-posta mesajlarına bulunan kelimelerin ya da karakterlerin ortalama yüzdesine eşit göstergede olan kelime ya da karakterler. Kelimeler ve karakterler spam ile eposta arasındaki en geniş farklılığı gösterecek şekilde seçilmişlerdir (Hestie ve ark. 2008)

	george	siz	sizin	hp	bedava	hpl	!	re	edu	taşınmış
spam	0.00	2.26	1.38	0.02	0.52	0.01	0.51	0.13	0.01	0.28
eposta	1.27	1.27	0.44	0.90	0.07	0.43	0.11	0.42	0.29	0.01

Amaç kullanıcının posta kutusu tıkanmadan önce spam süzücüsü oluşturabilen bir otomatik spam tespit edicisini tasarlamak. Tüm 4.601 eposta mesajlarında, gerçek sonuç (eposta biçimi) eposta ya da spam, eposta mesajlarında en sık görülen 57 kelime ya da noktalama işaretlerinin göreceli frekansları ile birlikte kullanılabilir. Bu bir sonuçları eposta ya da spam değişkenleri sınıfı olan ön bilgilendirmeli öğrenme problemidir. Bu problem aynı zamanda sınıflandırma problemi olarak tanımlanır. Çizelge 2.3’de spam ve epostalar arasındaki en geniş ortalamadaki kelime ve karakterlerim listesini göstermektedir. Problem üzerindeki öğrenme metodu hangi özelliklerin kullanıldıkları ve nasıl kullanıldıklarına karar vermek zorundadır: örneğin şu şekilde bir kural kullanılabilir:

eğer ($\%george < 0.6$) & ($\%siz > 1.5$) ise spam, değilse eposta

Bir başka kural aşağıdaki biçimde olabilir:

eğer ($0.2.\%siz - 0.3.\%george$) > 0 ise spam, değilse eposta

Bu problem için tüm hatalar eşit değildir; spamın süzgeçten geçmeyi başarması arzulanmamakta fakat bu durumun en az ciddi sonuçları olarak doğru epostaların süzülmesinden kaçılmak istenmektedir (Hestie ve ark. 2008).


Prostat kanseri ile ilgili başka bir öğrenme problemi örnek verilecek olunursa, bu örnek için veriler Şekil 2.26’da gösterilmiştir. Bu veriler (Stamey ve ark. 1989’den akt. Hestie ve ark. 2008)’dan alınmıştır. Bu çalışmada radikal

prostatektomi almış 97 erkek için, klinik ölçülerin sayısı ile prostat özel antijeni (PSA) seviyesi arasındaki korelasyon incelenmiştir. Hedef, log kanser hacmi (lcvol), log prostat ağırlığı (lweight), yaş, kapsül penetrasyonu log'u (lcp), gleason skoru (gleason) ve gleason 4 ya da 5 skorlarının yüzdesi (pgg45)'in de dahil olduğu bir dizi ölçümlerden PSA'nın log'unu (lpsa) tahmin etmektir. Şekil 2.25 değişkenlerin saçılım grafiğinin matrisidir, lpsa ile bazı korelasyonlar kanıt olmak ile birlikte göz ile iyi bir tahmin edici model düzenlemek zordur. Bu, sonuç ölçümü nicel olduğu için regresyon problemi olarak bilinen bir ön bilgilendirmeli öğrenme problemidir (Hestie ve ark. 2008).


Diğer bir örnek olan el yazısı rakam tanıma öğrenme problem örneğinde, veriler Amerikan posta işleri'nden zarfların üzerinde bulunan el yazısı posta kodlarından gelmektedir. Her bir görüntü ayrı tutulmuş tek haneli 5 adet rakam posta kodundandır. Görüntü, her bir piksel değişimi 0'dan 255'e kadar olan yoğunluğundaki, 16x16 sekiz-bit gri tonlamalı haritalardır (Hestie ve ark. 2008).

Bazı örnek görüntüler Şekil 2.27'de gösterilmiştir. Görüntüler yaklaşık olarak aynı büyüklükte ve aynı yönelimde normalize edilmişlerdir. Yapılmak istenilen, 16x16 piksel yoğunluğundaki matristen her bir görüntüyü (0,1,...,9) hızlı ve doğru bir şekilde tanımlamaktır (Hestie ve ark. 2008).

Eğer yeterli kesinlik yok ise sonuç algoritması, zarflar için bir otomatik sınıflandırma yönteminin bir parçasını kullanacaktır. Bu, hata oranların çok düşük olarak tutulması istenilerek postaların yanlış yöndendirilmesini önleyen bir sınıflandırma problemidir. Bu düşük hata oranından başarı sağlamak için bazı el yazması rakamlar bilinmeyen kategorisine atanır ve el ile yapılması yerine sınıflandırılırlar (Hestie ve ark. 2008).



Şekil 2.26. Prostat kanseri verilerin saçılım matrisi. İlk satır sırasıyla tahmin edicilerin her birine karşı gelen yanıtı göstermektedir. İki tahmin edici, svi ve gleason kategoriklerdir (Hestie ve ark. 2008'den akt.Stamey ve ark. 1989)



Şekil 2.27. Birleşik Devletler posta zarflarından el yazması rakam örnekleri (Hestie ve ark. 2008)

Öğrenme problemleri ile ilgili olarak bu kısımda verilecek son örnek; DNA mikroçiplerinin dışavurum örneğidir.

DNA deoksiribonükleik asit anlamına gelir ve insan kromozonlarını oluşturan temel maddedir. DNA mikroçipleri, ilgili gen için gösterilen mRNA (haberci ribonükleik asit)'nın ölçülen miktarı tarafından bir hücredeki bir genin dışavurumunu ölçer. Mikroçipler biyolojide atılım teknolojisi olarak düşünülmektedir. Hücrelerin bir tek örneklemeden gelen binlerce geni eş zamanlı olarak yapılan niceliksel çalışmaları kolaylaştırır.

Bir DNA mikroçipi nasıl çalışır sorusuna yanıt olarak; bir kaç bin genin nükleotit sıraları bir lam (mikroskop'da inceleneceklerin üzerine konulduğu cam parçası) üzerine basılır (Hestie ve ark. 2008).

Bir hedef örneklem ve referans örneklem kırmızı ve yeşil boya ile etiketlenir ve her biri lam üzerinde DNA ile melezleştirilir. Floreskopi ile, her bir konumda hybridize log (kırmızı ya da yeşil) yoğunlukları ölçülür. Sonuç, tipik olarak -6'dan 6'ta kadar olan aralıkta değişen referans örneğine göre hedefteki her bir genin dışavurum seviyeleri bir kaç bin rakamlardır. Pozitif değerler hedefe karşı referanstaki genlerin yüksek dışavurumlarını göstermektedir. Bu durumun tersi ise negatif genler için sözkonusudur (Hestie ve ark. 2008).

Bir gen dışavurum veri kümesi bir deneyi temsil eden her bir kolon ile, DNA mikroçip deneylerinin bir serisinden dışavurum değerlerini bir araya toplar. Böylece bireysel genleri temsil eden bir kaç bin sıra vardır ve onlarca sütunlar örneklemeleri temsil eder: belirginlik için sadece rastgele 100 örneklem satırı gösterildiği halde, özel bir örnek olan Şekil 2.28’de sergilenmiş 6830 gen (satırlar) ve 64 örneklem (sütunlar) vardır. Şekil 2.28 aralığı yeşilden (negatif) kırmızıya (pozitif) kadar olan veri kümesini ısı haritası gibi görüntüler. Örneklemeler farklı hastalardan alınan 64 kanser tümörüdür.

Bu problemdeki sorun genlerin ve örneklemeleri nasıl organize edileceğinin anlaşılmasıdır. Tipik sorular şunlardır:

- Genler arasındaki kendi profilleri açısından, hangi örneklemeler birbirlerine en çok benzemektedir?
- Örneklemeler arasında kendi profilleri açısından, hangi genler birbirine en çok benzemektedir?
- Belirli bir kanser örnekleme için belirli bir gen çok yüksek (ya da çok düşük) dışavurum gösterir mi?

Cevap değişkeni dışavurum seviyesi olmak üzere, iki kategorik tahmin değişkeni (genler ve örneklemeler) ile yukarıda anlatılan problem bir regresyon problemi olarak görülebilir. Buna rağmen muhtemelen daha çok kullanışlı olan görüş, ön bilgilendirmesiz öğrenme problemi gibidir. Örneğin yukarıdaki ilk soru için, bir şekilde birlikte kümelemek istenilen örneklemeler 6830 boyutlu uzayda noktalar olarak düşünülmektedir (Hestie ve ark. 2008).

2.2.1.1 Uzaktan Algılama

Uzaktan algılama verilerine uygulanan bilinen sınıflandırma tekniklerinin çoğu aslında ön bilgilendirmeli öğrenme ve ön bilgilendirmesiz öğrenme biçimlerinde yapılan çözümlenme teknikleridir. Bu teknikler uzaktan algılama paket programlarında ve uzaktan algılama kaynaklarında ön bilgilendirmeli sınıflandırma ya da ön bilgilendirmesiz sınıflandırma olarak bilinmektedirler. Uzaktan algılamada ön bilgilendirmeli sınıflandırma için, sınıflandırılması


yapılacak uzaktan algılanmış verilerin tamamından amaca göre örneklem seçilir ve seçilen örneklemelere hangi sınıflara ait olduğu bilgisi yüklenir.

Böylece ilgili örneklem verileri hangi sınıflara ait olduklarının ön bilgisine sahip olmuş olurlar. Örneğin paket program yardımı ile çoklu spektral bantlı uzaktan algılanmış uydu görüntüleri için ön bilgilendirmeli sınıflandırma yapılacak ise görüntü üzerinde seçilen okyanus, kara ve bulut kümeleri etiketlendiğinde asıl yapılan işlem görüntü üzerinde seçilen okyanus örnekleminde bulunan tüm piksellerin yansıma değerlerine okyanus ön bilgilendirmesi yapılarak okyanus sınıfına atanmalarıdır. Benzer durum kara ve bulut kümeleri içinde söz konusudur. Daha sonra yapılacak tüm görüntünün sınıflandırma analizleri örneklem piksellerin yansıma değerlerinin ön bilgilerine göre yapılır ve sonuçta tüm görüntü istenilen sınıflara atanmış olur.

Uzaktan algılamada ön bilgilendirmesiz sınıflandırma için uzaktan algılanmış verilere önceden örneklem ön bilgilendirmesi yapılmadan sınıflandırma yapılır. Örneğin piksel bazlı uzaktan algılanmış uydu görüntüsü ön bilgilendirmesiz sınıflandırmasında örneklem piksellerin yansıma değerlerinin ön bilgilendirmeleri söz konusu değildir. Bu yüzden bazı kaynaklarda ön bilgilendirmesiz sınıflandırma işlemine kümeleme denilmektedir.

Ön bilgilendirmeli sınıflandırma için aynı zamanda, aynı anlama gelen; denetimli sınıflandırma, kontrollü sınıflandırma ya da eğitilmiş sınıflandırma isimleride kullanılmaktadır.

Ön bilgilendirmesiz sınıflandırma için ise aynı zamanda, aynı anlama gelen; denetimsiz sınıflandırma, kontrolsüz sınıflandırma ya da eğitimsiz sınıflandırma isimleri ile kullanılır.



Şekil 2.28. DNA mikroçip verileri: İnsan tümör verileri için 6830 gen (satırlar) ve 64 örneklem (sütunlar)’ın dışavurum matrisi. Sadece rastgele 100 örneklem satırı gösterilmiştir. (Hestie ve ark. 2008)

Uzaktan algılamada, çok bilinen ve çok kullanılan ön bilgilendirmeli sınıflandırma tekniklerine örnek olarak; en çok olabilirlik sınıflandırma, Bayes sınıflandırma, paralelyüzlü sınıflandırma, en yakın uzaklık sınıflandırma, k-en yakın komşuluk sınıflandırıcısı, Isodata sınıflandırma, verilebilirken; çok bilinmeyen ve çok kullanılmayan ön bilgilendirmeli sınıflandırma tekniklerine örnek olarak; ayırım analizi, lojistik regresyon analizi ve destek vektör makineleri bu gruba örnek verilebilir. Yukarıdaki pragrafta anlatılan ön bilgilendirmeli sınıflandırma teknikleri parametrik ve parametrik olmayan teknikler olarak kendi aralarında ikiye ayrılmaktadır. Conover (1999)'a göre eğer anakütle olasılık dağılımı normal dağılım ise, \bar{X} ya da \bar{X}' 'yü esas alan bazı istatistikler, μ hakkında hipotez testleri için ya da μ 'nün tahmini için güven aralıklarını bulmak için kullanılabilir. Benzer bir şekilde anakütle standart sapması σ test edilebilir ve σ için eğer dağılım normal ise, her iki S veya s örneklem standart sapması esas alınarak güven aralığı oluşturulabilir. Bunlar parametrik metotlar olarak adlandırılır çünkü geçerlilikleri bilinen anakütle dağılım fonksiyonuna bağlıdır. Herhangi hipotez testi ya da güven aralığı anakütle dağılımı fonksiyonun bilinme ya da bazı bilinmeyen parametreler haricinde bilinmesi durumunda parametrik metot olarak adlandırılır.

Yine Conover (1999)'a göre parametrik olmayan metotlar parametrik metotların esas aldığı örneklemin rastgeleliği varsayımı gibi bazı aynı varsayımları esas alır. Buna rağmen parametrik olmayan metotlar belirli bir anakütle olasılık dağılımı varsayımında bulunmazlar, böylece bilinmeyen olarak kalabilen herhangi bir anakütleden herhangi olasılık dağılımından veriler için geçerli olurlar.

Bu durumda en çok olabilirlik, ayırım analizi gibi sınıflandırıcılar parametrik ön bilgilendirmeli sınıflandırma teknikleri iken, paralel yüzlü sınıflandırma, en kısa uzaklık, Isodata, k-ortalamlar ve k-en yakın komşuluk sınıflandırıcıları parametrik olmayan ön bilgilendirmeli sınıflandırma tekniklerine örnektir.

Uzaktan algılamada, çok bilinen ve çok kullanılan ön bilgilendirmesiz sınıflandırma tekniklerine örnek olarak; k-ortalamlar ve Isodata sınıflandırma, verilebilir. Bu iki sınıflandırma, hem ön bilgilendirmeli hem de ön bilgilendirmesiz sınıflandırma tekniklerinde kullanılmaktadır.

Campbell ve Wynne (2011), Isodata sınıflandırıcısının en kısa uzaklık metodunun bir çeşiti olduğu, buna rağmen Isodata sınıflandırıcısının ortaya çıkan sonuçları, basit en kısa uzaklık yaklaşımından türetilen sonuçlarından daha üstün olduğu sık sık düşünülmemekte olduğunu ve ön bilgilendirmeli sınıflandırmanın klasik modelinden hissedilir bir şekilde farklılık gösterdiğini bildirmişlerdir. Ayrıca Campbell ve Wynne (2011), Isodata sınıflandırıcısının hem ön bilgilendirmeli hem de ön bilgilendirmesiz metotların her ikisinin karakteristiklerini paylaşmasına (hibrid sınıflandırma) ve bu iki yaklaşım arasındaki ayrım hakkında kanıt sağlayan ima edilen mükemmel açıklamalar gibi net olmadığına iyi bir örnek olduğunu belirtmişlerdir.

Erdas uzaktan algılama paket programında Isodata sınıflandırıcısı, ön bilgilendirmesiz sınıflandırıcılar kısmında yer almaktadır.

k-ortalamar sınıflandırıcısı bazı kaynaklarda ön bilgilendirmesiz sınıflandırıcılar arasında yer almamasının sebebi piksel bazında ilk ya da ilksel (öncül) bilgilendirme yapılmamasındadır. Fakat ilk başta tahmini sınıf sayısının girilerek sınıf sayısı bazında ilk olarak bilgilendirme yapıldığının bilinmesinde yarar vardır. İlerideki bölümlerde teorik yapısı anlatılacak EM algoritmasının (expectation maximization algorithm) ilk parametre tahminlerini genellikle k-ortalamar kümeleme tekniği ile yapılmaktadır.

Campbell ve Wynne (2011)'e göre yukarıda bahsedilen sınıflandırma analizlerine ilave başka sınıflandırma analizleri mevcuttur: Sınıflandırma ve regresyon ağacı analizi, bulanık kümeleme, yapay sinir ağları, bağımsal sınıflandırma, nesne tabanlı sınıflandırma, bu tip sınıflandırıcılara örnektir.

2.2.1.2 Veri Madenciliği

Veri madenciliği büyük ölçekli verilerden tanımlayıcı, kavraması güçlü, ilginç ve kendine has örüntülerin yanı sıra anlaşılabilir ve tahmin modellerini keşfetme sürecidir (Zaki ve Meria 2014).

Basitçe ifade edilmek gerekirse veri madenciliği büyük ölçekli verilerden çıkarılmış maden veya maden çıkarma bilgisi gibi benzetimle nitelendirilmektedir.

Veri madenciliği, veri tabanı ve veri ambarı teknolojileri, istatistik, makine öğrenmesi, yüksek performanslı hesaplama, örnek ya da örüntü tanıma, sinir ağları, veri görselleştirme, bilgi geri kazanım, görüntü ve sinyal işleme ile

mekansal ve zamansal veri analizleri gibi çoklu disiplinlerden teknolojinin bir entegrasyonunu içerir (Han ve Kamber 2006).

Veri madenciliğinin istatistiksel öğrenme ile ilgili kullanım alanlarına örnek vermek gerekirse Han ve Kamber (2006)'ya göre siber saldırı tespiti için veri madenciliği algoritmaları geliştirilmiştir: Veri madenciliği algoritmaları kötüye kullanma ya da anomali tespiti için kullanılabilir. Kötüye kullanma tespiti için ön bilgilendirme (eğitim) verileri normal ya da saldırı olarak etiketlenmiştir. Bir sınıflandırıcı sonra bilinen saldırıları tespit etmek için türetilir. Bu alandaki araştırmalara sınıflandırma algoritmaları uygulaması, ilişkisel kural madenciliği ve maliyet duyarlı modelleme dahildir. Anomali tespiti normal davranış modelleri ve normal davranıştan olan önemli sapmaları otomatik bir şekilde tespit eden model oluşturur. Ön bilgilendirmeli ya da ön bilgilendirmesiz öğrenme kullanılabilir. Ön bilgilendirmeli yaklaşımda, model normal olarak bilinen ön bilgilendirilmiş (eğitim) verileri esas alınarak geliştirilmiştir. Ön bilgilendirmesiz yaklaşımda ise ön bilgilendirme verileri hakkında hiç bir bilgi verilmez. Anomali tespiti araştırmalarına sınıflandırma algoritmalarının uygulamaları, istatistiksel yaklaşımlar, kümeleme ve aykırı değer analizi dahildir. Kullanılan teknikler, verimli ve ölçeklendirilebilir, yüksek hacimli ağ veri taşıma kapasitesine sahip, boyutluluk ve heterojenliğe sahip olmalıdırlar (Han ve Kamber 2006).

2.2.1.3 Yapay Zeka

Yapay zekanın sekiz farklı tanımı ilerleyen paragraflarda iki boyutlu olarak ortaya konulmuştur (Russell ve Norvig 2010):

Düşünce süreci, muhakeme ve insanca düşünme ile ilgili tanımlar: Düşünen bilgisayarlar yapmak heyecan verici yeni bir çabadır. Tam ve literal anlamda akla sahip makineler (Haugeland, 1985'den akt. Russell ve Norvig 2010). İnsan düşüncesi ile ilişkilendirdiğimiz faaliyetlerin otomasyonu, karar verme, problem çözme, öğrenme gibi aktiviteler (Hellman, 1978'den akt. Russell ve Norvig 2010).

Düşünce süreci, muhakeme ve rasyonel düşünme ile ilgili tanımlar: Hesaplama modelleri kullanımı yoluyla zihinsel yetenekler hakkında çalışma (Charniak ve McDermott, 1985'den akt. Russell ve Norvig 2010). Algılama,

sebepler ve davranışları olası yapan hesaplamalar ile ilgili çalışmalar (Winston,1992'den akt. Russell ve Norvig 2010).

Davranış ve insanca tutum ile ilgili tanımlar: İnsanlar tarafından yapıldığında zeka gerektiren fonksiyonları yerine getiren makineleri oluşturma sanatı (Kurzweil,1990'den akt. Russell ve Norvig 2010). Şu anda insanların yaptığı şeylerden daha iyisini bilgisayarların nasıl yapabileceğine dair çalışma (Rich ve Knight, 1991'den akt. Russell ve Norvig 2010).

Davranış ve rasyonel hareket ile ilgili tanımlar: Hesaplamalı zeka, kullanıcıların ne bildiği hakkındaki bilgileri esas alarak karar verebilen sofistike yazılımın tasarımı çalışmasıdır (Poole ve ark., 1998'den akt. Russell ve Norvig 2010). Yapay zeka insan eserlerindeki akıllı davranış ile ilgilidir (Nilsson, 1998'den akt. Russell ve Norvig 2010).

Çevresinden yeterli tecrübe edindikten sonra kendi ilk bilgisi, rasyonel temsilcinin davranışı onun öncül bilgisinden etkin bağımsız olabilir. Böylece öğrenme ile birleşme, bir ortamda geniş bir çeşitlilik çevresinde başarılı olacak tek bir rasyonel temsilci tasarımını sağlar. Tüm temsilciler kendi performanslarını öğrenme yolu ile geliştirebilirler (Russell ve Norvig 2010).

2.2.1.4. Bioinformatik

Bioinformatik bilgisayar bilimi ile biyoloji bilimi arasında arayüz olan bir disiplinlerarası araştırma sahasıdır. Çeşitli tanımlamalar literatürde ve dünya çapında ağda mevcuttur; bazıları diğerlerinden daha kapsamlıdır. (Luscombe ve ark.'den akt. Xiong 2006) tanımı ile bioinformatik biyoloji ve informatik alanlarının birleşimidir: Bioinformatik DNA, RNA ve proteinler gibi biyolojik makromoleküller ile ilişkili bilginin depolanması, geri alınması idare edilmesi ve dağıtımı için bilgisayarları kullanan teknolojiyi içerir. Bilgisayarların kullanımına vurgu yapılmasının nedeni, genomik verilerin analizinde bir çok görevin çokça tekrarlanması ya da matematiksel olarak karmaşık olmasıdır.

Bilgisayarların kullanılması bilgi toplamak ve bilgi inşa etmek için genom madenciliğinde kesinlikle vazgeçilmezdir.

Bioinformatik sayısal (hesaplamalı) biyoloji olarak bilinen ilişkili alandan farklıdır. Bioinformatik, sıkça sayısal moleküler biyoloji olarak düşünülen

genlerin ve genomların ve bunların ilişkili ürünlerinin sırası, yapısı ve fonksiyonel analizi ile sınırlandırılmıştır. Buna rağmen sayısal biyoloji hesaplamasının da dahil olduğu tüm biyolojik alanları kapsar. Örneğin, ekosistemlerin matematiksel modelleri, nüfus dinamikler, davranışsal çalışmalarda oyun teorisi ve fosil kayıtlarını kullanarak filogenetik yapı tüm hesaplama araçlarını kullanır, fakat biyolojik makromolekülleri içermesi gerekmez (Xiong 2006).

Bu ayrımın yanında, iki terimin ilişkili olduğu hakkında diğer görüşlerde dikkate değer hiçbir şey yoktur. Örneğin bioinformatiğin bir versiyon tanımı, biyolojik verilerin her türlü yönteminde sayısal araçların uygulaması ve gelişmesi iken sayısal biyoloji, bioinformatik için kullanılan algoritmaların teorik gelişimini daha fazla sınırlandırılmıştır. Şu anda tanım üzerinde var olan karışıklık, canlı ve hızlı gelişen yeni alanın doğasını kısmen yansıtabilir. Bioinformatiğin son amacı yaşayan bir hücreyi ve moleküler seviyedeki fonksiyonları daha iyi anlamaktır. Ham moleküler dizisi ve yapısal veriler analiz edilerek, bioinformatik araştırma yeni sezgiler oluşturabilir ve hücreye küresel bir bakış açısı sağlayabilir. Bunun nedeni, hücrenin fonksiyonlarının nihai olan sıralı gelen verilerin analizleri tarafından daha iyi anlaşılabilir olmasıdır. Çünkü genetik bilgi akışı, DNA, proteinlere çevrilmiş olan RNA için transkripsiyonu olan biyolojinin ya da merkezi doktrin tarafından dikte edilmiştir. Hücresel fonksiyonların yetenekleri sonunda sıraları tarafından belirlenen esasen proteinler tarafından gerçekleştirilirler. Böylece fonksiyonel problemleri çözmede dizileri kullanma ve bazen yapısal yaklaşımların verimli çaba olduğu kanıtlanmıştır (Xiong 2006).

Dışavurum profillerindeki hesaplanmış genler arasındaki uzaklıklar esas alındığında, benzer dışavurum örneklerindeki genler gruplanabilirler. Her iki sınıflandırma analizleri ön bilgilendirmeli ya da ön bilgilendirmesiz olabilir. Ön bilgilendirmeli analiz verilerin içine bir takım önceden tanımlanmış kategorilerin sınıflandırılmasını kasteder. Örneğin deneyin amacına bağlı olarak veriler önceden tanımlı olarak hasta ya da normal kategorileri olarak sınıflandırılabilir (Xiong 2006).

Ön bilgilendirmesiz analiz önceden tanımlı kategorileri varsaymaz fakat veri kategorileri tanımlamaları asıl benzer örneklere göre yapılır. Ön bilgilendirmesiz analiz aynı zamanda ilişkili profillere sahip genlerin kümeler halindeki grup örnekleri biçimindeki kümeleme olarakta adlandırılır. Mikroçip

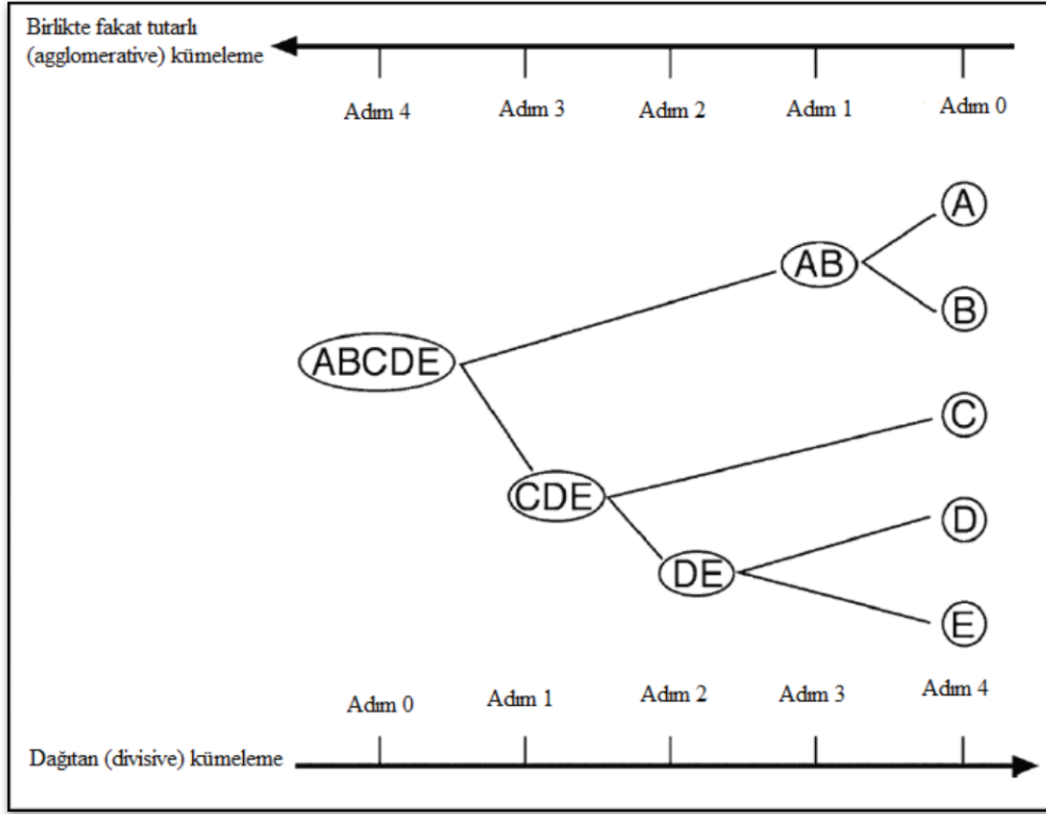
verileri için, kümeleme analizi (ön bilgilendirmesiz analiz) başka bir gen ile birlikte ifade edilen ve birlikte düzenlenmiş genleri tanımlar (Xiong 2006).

Bir kategori içerisinde bulunan genlerin dışavurumları farklı kategoriden genlerin dışavurumundan daha fazla benzerliğe sahiptir. Genler birlikte düzenlenmiş ya da eş düzenlenmiş olduklarında ilişkili fonksiyonellikleri normal olarak yansıtırlar. Gen kümeleme yoluyla, önceden karakterize edilmemiş genlerin fonksiyonları keşfedilebilir. Kümeleme metotları hiyerarşik kümeleme ve bölümlenmeli kümeleme metotlarını içerir. Bu durumlara örnek olarak k-ortalamar, kendinden düzenlenen haritalar ya da özdüzenleyici haritalar (SOM) verilebilir.

Kümeleme algoritmaları ayrıca iki tipe ayrılabilir; birlikte fakat tutarlı kümeleme “külçelenmiş çiçek başı” gibi benzetme ile yapılan ve dağıtan (Şekil 2.29). Birlikte fakat tutarlı kümeleme metodu iki en çok benzer veri noktasının kümelendirilmesi tarafından başlar ve tüm veri grupları birleştirilesiye kadar benzerliklere göre art arda veri birleştirme süreci tekrarlanır. Bu metot aynı zamanda aşağıdan yukarı yaklaşımı olarakta bilinir. Dağıtan methodu, bir tek sınıf içerisindeki yumru ya da kitle gibi düşünülen tüm verilerin noktaları tarafından diğer bir yol etrafında çalışır ve tüm hiyerarşik seviyeler çözülesiye kadar benzeşmezlik durumuna göre art arda verileri küçük gruplar içerisine böler. Bu metot aynı zamanda yukarıdan aşağıya yaklaşımı olarak bilinir (Xiong 2006).

2.2.1.5. Diğer Alanlar

Teknolojinin gelişmesine bağlı olarak bilgisayarlar ve teknik aletler sayesinde gözlemlenerek elde edilecek olan verilerin miktarlarının daha da artması ve araştırma konuları hakkında daha da ayrıntılı veriler elde edilecek olması kuvvetle muhtemel olduğundan bu duruma bağlı olarak disiplinler arası yeni ilişkilerin ortaya çıkması ile yeni istatistiksel ve istatistiksel öğrenme ile ilgili tekniklerin keşfedilecek olması kaçınılmazdır. Bu durum ortaya kendine yeni uygulama alanları bulan şu anda mevcut olan veri madenciliği, yapay zeka,



Şekil 2.29. Birlikte fakat tutarlı (agglomerative) kümeleme ile dağıtan (divisive) kümeleme metodlarının arasındaki farklılığı gösteren şematik betimleme (Xiong 2006)

bioinformatik gibi alanlarda olduğu gibi çeşitli disiplinler arası yeni diğer alt alanların ortaya çıkması neden olacaktır.

Günümüzde istatistiksel öğreniminde kullanıldığı disiplinler arası diğer alanlara örnek olarak uzay, robotik, insansız hava araçları, tıp, ilaç araştırmaları gibi alanlar gösterilebilir. Örneğin Dünya’da bazı üniversitelerin robot futbol takımları sahada otonom hareket etmektedir. Bu durumda yazılımlarında istatistiksel öğrenme ile yapılan sınıflama teknikleri kaçınılmazdır. İnsansız hava araçları günümüzde belirli alanların belirli spektral aralıklarındaki tekli ya da çoklu bant görüntüleri üzerinden işlemler yapmaktadır. Örneğin tarım alanında insansız hava araçları ile amaca göre yapılan istatistiksel öğrenmeye dayalı sınıflandırma teknikleri ekonomik kazanç ve tasarruf sağlamaktadır. Bu teknikler yapılan analizlerin önemli bir kısmını oluşturmakla birlikte ileride gerçekleştirilecek olan insansız hava araçları ile tespit anında ilaçlama gibi işlemlerde istatistiksel öğrenme ile yapılacak olan sınıflandırma teknikleri ve önemi daha da kaçınılmaz olacaktır. Uzaktan algılama ile ilgili olan bu tip

örnekler tarım haricindeki alanlarada verilebildiği gibi uzaktan algılamanında değişik biçimleri için de verilebilir.

Benzer şekilde istatistiksel öğrenmeye dayalı yapılan sınıflandırma teknikleri için verilebilecek disiplinler arası örneklerde çoğaltılabilir. Şu anda oldukça önemli olan istatistiksel öğrenme tabanlı sınıflandırmanın gelecekte önemi daha da artacak ve daha iyi performansa sahip ve daha yeni istatistiksel öğrenmeye dayalı teknikler geliştirmeye çalışılacaktır. Şu andaki tekniklerde olduğu gibi geliştirilecek olan bu yeni teknikler çeşitli bilimsel disiplinlerde ve bilimsel disiplinler arası alanlarda yeni keşiflere yani bilime yol gösterici olacaktır.

2.2.2. İstatistiksel Öğrenme Tabanlı Olarak Kullanılan Bazı Güçlü, Sınıflandırıcılar, Algoritmalar ve Teorik Açıklamaları

İstatistiksel öğrenme tabanlı bir çok sınıflandırıcı mevcuttur. Bu sınıflandırıcıların güvenilirlikleri, performansları teorik yapılarındaki varsayımların sağlanıp sağlanmamasına, verilerin durumuna ve amaca göre değişiklik gösterir. Bu tezde uzaktan algılanmış görüntü verilerine dayanılarak istatistiksel öğrenme tabanlı modifiye sınıflandırıcı üzerine çalışılacağı için, fikir vermesi açısından uzaktan algılanmış uydu görüntüleri için çok kullanılan ve güvenilirlik yüzdesi çok olduğu düşünülen ve araştırılacak istatistiksel öğrenme tabanlı modifiye sınıflandırıcıya yakınlığından dolayı en çok olabilirlik sınıflandırıcısı, Bayes sınıflandırıcı, teorik açıklamaları ve uzaktan algılamada nasıl kullanıldıkları açıklanacaktır.

Yapılacak modifiye araştırma EM Algoritması (Expectation Maximization Algorithm) esas alınarak uzaktan algılanmış görüntülere uygulanacağı için EM Algoritmasının teorik yapısı ve uzaktan algılamaya nasıl uygulanacağı ayrı bir başlık altında anlatılacaktır.

2.2.2.1. En Çok Olabilirlik Kestiricisi ve Sınıflandırması

En çok olabilirliğin esası aslında örneklemin anakütlenin temsilcisi olmasına ve olasılık yoğunluk fonksiyonunu PDF olasılık kütle fonksiyonunu (PMF) $f_{\theta}(x)$ en çok yapan parametre değerini kestirici olarak seçme varsayımına dayanır .

(X_1, X_2, \dots, X_n) PDF (PMF) $f_{\theta}(x_1, x_2, \dots, x_n)$ rastgele bir vektör olsun.

fonksiyon

$$L(\theta; x_1, x_2, \dots, x_n) = f_{\theta}(x_1, x_2, \dots, x_n) \quad (2.10)$$

θ 'nın bir fonksiyonu olarak düşünülür, olabilirlik fonksiyonu olarak isimlendirilir.

Genellikle θ çoklu parametre olacaktır. Eğer (X_1, X_2, \dots, X_n) iid yani bağımsız özdeşçe dağılmış, PDF (PMF) f_{θ} ile birlikte olabilirlik fonksiyonu:

$$L(\theta; x_1, x_2, \dots, x_n) = \prod_{i=1}^n f_{\theta}(x_i) \quad (2.11)$$

$\theta \subseteq R_k$ ve $X = (X_1, X_2, \dots, X_n)$ olsun

En çok olabilirlik kestiricisinin esası θ 'nın $\hat{\theta}(X)$ gibi $L(\theta; x_1, x_2, \dots, x_n)$ 'i en çoklayan, yani, $R_n \rightarrow R_k$ 'nin $\hat{\theta}$ 'ni karşılayan bir eşlemesini bulan bir kestiricisinin seçimininden oluşur.

$$L(\hat{\theta}; x_1, x_2, \dots, x_n) = \sup_{\theta \in \Theta} L(\theta; x_1, x_2, \dots, x_n) \quad (2.12)$$

Sabitler kestirici olarak kabul edilmemektedirler. Eğer bir $\hat{\theta}$ 'yı karşılayan Denklem (2.12) varsa, en çok olabilirlik kestiricisi olarak adlandırılır (maximum likelihood estimator) (MLE)

Olabilirlik fonksiyonunun logaritması ile çalışmak elverişlidir. Logaritma bir tekdüze fonksiyon olduğu için

$$\log L(\hat{\theta}; x_1, x_2, \dots, x_n) = \sup_{\theta \in \Theta} \log L(\theta; x_1, x_2, \dots, x_n) \quad (2.13)$$

Θ , R_k 'nin açık alt kümesi olsun, varsayalım $f_{\theta}(x)$ pozitif, θ 'nın türevlenebilir fonksiyonu olsun (Rohatgi ve Saleh 2009).

Yani Θ 'nın bileşenlerinin içinde birinci dereceden kısmi türevler mevcut olsun. Eğer bir üst sınırların en küçüğü (supremum) $\hat{\Theta}$ var ise, bu olabilirlik denklemlerini sağlamalıdır.

$$\frac{\partial \log L(\hat{\Theta}; x_1, x_2, \dots, x_n)}{\partial \theta_j} = 0, \quad j = 1, 2, \dots, k, \quad \theta = (\theta_1, \dots, \theta_k) \quad (2.14)$$

Denklem (2.14)'deki olabilirlik eşitliğinin değişkenlerden en azından bir tanesinin sıfıra eşit olmayan herhangi kökü, MLE gevşek sezgi içinde olarak adlandırılır. Olabilirlik fonksiyonunun kesin en çok değerini sağlayan bir parametre değeri MLE katı sezgi içinde (tam anlamıyla), ya da basitçe bir MLE olarak adlandırılır.

Eğer $\Theta \subseteq \mathbb{R}$, ise hala bir çok problem olabilir. Sıklıkla, olabilirlik denklemleri $\partial L / \partial \theta = 0$ birden fazla köke sahiptir ya da olabilirlik fonksiyonu Θ 'nın içinde her yerde türevlenemez ya da $\hat{\Theta}$ en son (terminal) değer olabilir. Bazen olabilirlik denklemleri oldukça karmaşık olabilir ve açıkça çözmek zor olabilir. Bu durumda bir kestirici elde etmek için sayısal prosedüre başvurmak zorunda kalınabilir. Benzer açıklamalar çoklu parametre durumundada uygulanır.

(X_1, X_2, \dots, X_n) , $N(\mu, \sigma^2)$ 'den her iki μ ve σ^2 'nin bilinmediği bir örneklem olsun. Burda $\Theta = \{N(\mu, \sigma^2), -\infty < \mu < \infty, \sigma^2 > 0\}$. Olabilirlik fonksiyonu:

$$L(\mu, \sigma^2; x_1, x_2, \dots, x_n) = \frac{1}{\sigma^n (2\pi)^{n/2}} \exp \left[-\sum_{i=1}^n \frac{(x_i - \mu)^2}{2\sigma^2} \right] \quad (2.15)$$

ve

$$L(\mu, \sigma^2; x) = -\frac{n}{2} \log \sigma^2 - \frac{n}{2} \log (2\pi) - \frac{\sum_{i=1}^n (x_i - \mu)^2}{2\sigma^2} \quad (2.16)$$

olabilirlik eşitlikleri

$$\frac{1}{\sigma^2} \sum_{i=1}^n (x_i - \mu) \quad (2.17)$$

ve (Rohatgi ve Saleh 2009)

$$-\frac{n}{2} \frac{1}{\sigma^2} + \frac{1}{\sigma^4} \sum_{i=1}^n (x_i - \mu)^2 = 0 \quad (2.18)$$

Denklem (2.17) μ için çözüldüğünde,

$$\mu = \bar{X} \quad (2.19)$$

ve bu sonuç denklem (2.18)'de yerine konulduğunda

$$\hat{\sigma}^2 = \sum_{i=1}^n \left[\frac{(x_i - \bar{X})^2}{n} \right] \quad (2.20)$$

Bulunur, $(\hat{\mu}, \hat{\sigma}^2) \in \Theta$ olduğu olasılık 1 ile anlaşılmaktadır. $(\hat{\mu}, \hat{\sigma}^2)$ 'in olabilirlik fonksiyonunu en üst düzeye çıkardığı ya da en büyüttüğü gösterilmiştir. Öncelikle dikkate alınması gerekir ki σ^2 ne olursa olsun \bar{X} , $L(\mu, \sigma^2; x)$ 'i en büyütür. $L(\mu, \sigma^2; x) \rightarrow 0$ olduğu için $|\mu| \rightarrow \infty$ olarak ve bu durumda $L(\hat{\mu}, \sigma^2; x) \rightarrow 0$, $\sigma^2 \rightarrow 0$ olarak ya da ∞ her ne zaman $\hat{\Theta} \in \Theta$, $\hat{\Theta} = (\hat{\mu}, \hat{\sigma}^2)$. Hatırlatmak gerekir ki $\hat{\sigma}^2$, σ^2 için yansız değildir. Aslında:

$$E\hat{\sigma}^2 = \left[\frac{(n-1)}{n} \right] \sigma^2 \quad (2.21)$$

dir. Fakat

$$\frac{n\hat{\sigma}^2}{(n-1)} = S^2 \quad (2.22)$$

bilindiği üzere yansızdır.

Aynı zamanda $\hat{\mu}$ yansızdır ve her iki $\hat{\mu}$ ve $\hat{\sigma}^2$ tutarlıdır. İlave olarak, $\hat{\mu}$ ve $\hat{\sigma}^2$, μ ve σ^2 için momentlerin kestirme yöntemidir. Ayrıca $\hat{\mu}$ ve $\hat{\sigma}^2$ birleşik yeterlidir.

Sonuç olarak dikkate alınması gerekir ki eğer σ^2 biliniyorsa $\hat{\mu}$, μ 'nün en çok olabilirlik kestiricisidir (MLE); fakat μ biliniyor ise σ^2 'nin en çok olabilirlik kestiricisi $\hat{\sigma}^2$ değil, fakat (Rohatgi ve Saleh 2009):


$$\frac{\sum_1^n (X_i - \mu)^2}{n} \quad (2.23)$$

En çok olabilirlik kestiricisidir (Rohatgi ve Saleh 2009).

Doğada sınıflandırılan sınıflar, spektral örneklerindeki doğal çeşitliliklerini sergilerler. İlaveten değişkenlik, sisin etkisi, topografik gölge, sistem gürültüsü ve karma piksellerin etkisi olarak eklenirler. Sonuçta uzaktan algılama görüntüleri nadiren spektral saf sınıfları kayıt eder; daha tipik olarak, her bir bantta parlaklığın bir aralığını gösterirler. Şimdiye kadar kabul edilen sınıflandırma stratejelerinin spektral kategoriler içerisinde mevcut olabilecek çeşitliliği ve ayrı kategoride spektral değerlerin frekans dağılımlarının üst üste binmesinden dolayı ortaya çıkan sorunlar ele alınmayarak düşünülmemiştir. Örnek verilmek gerekirse, paralel yüzlü bir sınıflandırmanın uygulaması için, sınıfların üst üste binmesi ciddi bir problemdir. Bunun nedeni spektral verilerin uzayı daha sonra sınıflandırma için ayrı ayrı birimlerin içerisine temizce ayıramamasıdır. Bu tip durumların sıkça ortaya çıkmasının sebebi dikkatin daha ziyade kolayca ve doğru bir şekilde diğer sınıflandırıcılar tarafından sınıflandırılan spektral bir biçimde benzer olma eğilimdeki bu piksellerin sınıflandırılması üzerine odaklanılmış olmasıdır.

Sonuç olarak, (Şekil 2.30)'de resimlendirilen durum yaygındır. Sayısal görüntünü dörtte üçü ormanlık araziden ve dörtte biri tarım arazisinden oluştuğu varsayalım. İki sınıf orman ve tarım arazisi ortalama parlaklıklara göre farklılaştırılırlar. Fakat uç ya da sıra dışı değerler (orman piksellerinin çok parlak olması veya mısır piksellerinin çok koyu olması) iki frekans dağılımları üst üste binen alanda benzerdirler (Campbell ve Wynne 2011).

Belirginleştirmek için (Şekil 2.30) sadece bir tek spektral bant için verileri göstermektedir. Parlaklık değeri 45 üst üste binen her iki ormanlık arazi ya da tarım arazisi sınıflarına net bir atama yapılamayan bölgede yer almaktadır. Yukarıda bahsedilen karar kuralı türü kullanılarak, isteğe bağlı sınır konulmadığı sürece hangi grubun bu pikselleri kabul edeceğine karar verilemez. Bu tip durumlarda etkili bir sınıflandırma için göreceli olabilirlikler: 45 ormanlık arazinin bir üyesidir ve 45 tarım arazisinin bir üyesidir gibi düşünülebilir. Daha sonra eğitim verileri bilgisi verilmiş olan doğru bir sınıflandırma olasılığını en büyüklüyecek yani maksimize edecek sınıf seçilebilir (Campbell ve Wynne 2011).



Şekil 2.30. En çok olabilirlik sınıflandırması. Bu frekans dağılımları iki ön bilgilendirme alanlarını temsil eden piksellerdir; her iki kategoride ortak olan piksel değerleri üst üste binen alanı tasvir eder. Sınıflara atanan pikseller için her sınıfın temel tanımlamaların tüm frekans dağılımındaki üst üste binen bölgelerindeki piksellerin ilişkisi. Burada iki histogramlar arasındaki ilişki piksel değeri 45 ile gösterilmiştir. Bu değer in orman (O) sınıfına ait olması tarım (T) sınıfından daha olasıdır (Campbell ve Wynne 2011)

Bu tip strateji en çok olabilirlik sınıflaması olarak bilinir ve sınıfların ortalamalarını ve varyanslarını tahmin etmenin bir yolu olarak daha sonra olasılıklarını tahmin etmek için kullanılan ön bilgilendirme ya da eğitim verilerini kullanır. En çok olabilirlik sınıflandırıcı atama sınıflandırmalarda sadece ortalama ya da ortalama değerler olarak düşünülmez her bir sınıfın içindeki parlaklık değerlerinin değişkenliği olarakta düşünülür. En çok olabilirlik karar kuralı eş zamanlı olarak bir kaç sınıf ve birkaç spektral kanalı dikkate alarak niceliksel olarak uygulanan biçimde güçlü bir sınıflama tekniğidir. Yoğun şekilde hesaplamaları gerektirir. Böylece daha kolay tekniklerin bir çoğundan daha çok bilgisayar kaynağı gerektirmenin dez avantajına sahiptir. Aynı zamanda daha çok diğer birçok ön bilgilendirme tekniklerine göre ön bilgilendirme ya da eğitim verilerindeki değişime duyarlıdır. Tahmin edilen olasılıkların hesaplanması her iki ön bilgilendirme verileri ve sınıfların kendilerinin çok değişkenli normal (Gaussian) frekans dağılımları göstermesi varsayımına dayanır. Yukarıda tartışıldığı üzere, bu ön bilgilendirme verilerinin tek şekilli dağılımları göstermek zorunda olduğu bir nedendir. Uzaktan algılanmış görüntülerden elde edilmiş veriler sık sık tam anlamı ile bu kurala bağlı kalmasalarda sapmalar sürecin kullanılışılığı muhafaza edecek şekilde küçüktür. Yinede ön bilgilendirme verileri dikkatli seçilmez ise hata getirebilir (Campbell ve Wynne 2011).

2.2.2.2. Bayes Çıkarımı, Kuralı, Risk, Kestirim ve Sınıflandırıcısı

Bayes teoremi ile ilgili bir parametre Θ hakkında ya da gözlemlenmemiş veriler \tilde{y} hakkında istatistiksel sonuç, olasılıksal ifadeler açısından yapılır. Bu olasılıksal ifadeler y 'nin gözlemlenmiş değeri üzerinde koşulludur. Basit bir şekilde simgesel olarak $p(\Theta|y)$ ya da $p(\tilde{y}|y)$ şeklinde yazılır. Aynı zamanda herhangi bir ortak değişken x 'in bilinen değerleri üzerinde koşulludur. Bu gözlemlenmiş veriler üzerindeki Bayes teoremi ile ilgili olan sonuç, bir çok ders kitaplarında bilinmeyen doğru değer Θ 'ya koşullu olası y değerlerinin dağılımı üzerinden kullanılan Θ 'yı ya da \tilde{y} 'i tahmin etme yönteminin geçmişi kapsayan değerlendirmesi şeklinde tanımlanan istatistiksel sonuç yaklaşımından ayrılmış olan şartlandırmanın temel seviyesindedir. Bu farklılığa rağmen, bir çok basit analizlerde yüzeysel benzer sonuçlar, istatistiksel çıkarımdaki iki yaklaşımın sonuçlarından görülecektir. Buna rağmen, analizler Bayes teoremi ile ilgili metotlar kullanılarak daha çok karmaşık problemler için kolayca genişletilerek elde edilmiştir (Gelman ve ark. 2004).

Verilen y için Θ hakkında olasılık ifade etmek için, Θ ve y için bir birleşik olasılık dağılımı modelinin sağlanması ile başlanmalıdır. Birleşik olası kütle ya da yoğunluk fonksiyonu sıkça kastedilen önsel dağılım $p(\Theta)$ ve örneklem dağılımı (ya da verilerin dağılımı) $p(y|\Theta)$ sırasıyla iki yoğunluğun bir ürünü gibi yazılabilir:

$$p(\Theta, y) = p(\Theta)p(y|\Theta) \quad (2.24)$$

Bayes kuralı olarak bilinen koşullu olasılığın temel özelliği kullanılarak sonsal (posterior) yoğunluğu verir:

$$p(\Theta|y) = \frac{p(\Theta, y)}{p(y)} = \frac{p(\Theta)p(y|\Theta)}{p(y)}, \quad (2.25)$$

$$p(y) = \sum_{\Theta} p(\Theta)p(y|\Theta) \quad (2.26)$$

ve toplam Θ 'nın tüm olası değerleridir Denklem (2.26).

ya da Θ 'nın sürekli olması halinde:

$$p(y) = \int p(\theta)p(y|\theta)d\theta \quad (2.27)$$

Denklem (2.26)'nın biçiminde θ 'ya bağımlı olmayan $p(y)$ faktörü sabitlenmiş y ile dahil edilmemiştir, böylece bir sabit olarak kabul edilebilir, normalleşmemiş sonsal yoğunluk Denklem (2.28)'in sağ tarafında elde edilmiştir:

$$p(\theta|y) \propto p(\theta)p(y|\theta) \quad (2.28)$$

Bu basit ifadeler Bayes teoremi ile ilgili çıkarımın teknik çekirdeğini özetler: Her hangi belirli bir uygulamanın ilk vazifesi model $p(\theta|y)$ 'yi geliştirmek ve uygun şekillerde $p(\theta|y)$ 'yi özetlemek için gerekli hesaplamaları gerçekleştirmektir (Gelman ve ark. 2004).

Bilinmeyen gözlemlenebilir hakkında çıkarımlar yapmak, sıklıkla tahmin edici (kestirici) çıkarımlar olarak adlandırılır. Benzer mantık takip edilerek; var olan y olarak önce, bilinmeyen dağılımlı fakat gözlemlenebilir y :

$$p(y) = \int p(y, \theta)d\theta = \int p(\theta)p(y|\theta)d\theta \quad (2.29)$$

Denklem (2.29) sıklıkla y 'nin marjinal dağılımı olarak adlandırılır. Fakat daha çok bilgilendirme amaçlı ismi önsel tahmin edici ya da kestirimci dağılımdır. Önsel olarak adlandırılmasının nedeni, sürecin önceki bir gözlemi üzerinde koşullu olmamasıdır. Tahmin edici adlandırılmasının nedeni ise gözlemlenebilir bir miktar için dağılım olmasıdır.

y verileri gözlemlendikten sonra, bilinmeyen gözlemlenebilir \tilde{y} 'ler kestirilebilir. Örneğin $y = (y_1, \dots, y_n)$ bir ölçek üzerinde n kez ağırlıklandırılmış bir nesnenin kaydedilen ağırlıklarının vektörü olabilir. $\theta = (\mu, \sigma^2)$, ölçeğin, nesne ve ölçüm varyansının bilinmeyen gerçek ağırlığı olabilir ve \tilde{y} yeni bir ağırlıkta planlanan, henüz kaydedilecek ağırlık olabilir. \tilde{y} 'nin dağılımı sonsal tahmin edici ya da kestirici dağılım olarak adlandırılır. Sonsal olarak adlandırılmasının nedeni, gözlemlenmiş y 'ye koşullu olması ve tahmin edici olarak adlandırılmasının nedeni gözlemlenebilen \tilde{y} için bir tahmin edici olmasıdır:

$$\begin{aligned}
p(\tilde{y}|y) &= \int p(\tilde{y}, \theta | y) d\theta \\
&= \int p(\tilde{y} | \theta, y) p(\theta | y) d\theta \\
&= \int p(\tilde{y} | \theta) p(\theta | y) d\theta
\end{aligned} \tag{2.30}$$

Denklem (2.30)'da ikinci ve üçüncü satırlar, θ 'nın sonsal dağılımı üzerindeki koşullu tahmin edicilerin bir ortalaması gibi sonsal tahmin edici dağılımı göstermektedir. Son satırın uygun olmasının sebebi y ve \tilde{y} , bu model içinde verilen θ için koşullu bağımsız olmalarıdır. θ 'nın bir fonksiyonu olarak da dikkate alındığında sabitlenmiş y için, olabilirlik fonksiyonu olarak isimlendirilir. Bu yolla Bayes teoremi ile ilgili çıkarım bazen verilmiş örneklem verisi için, herhangi iki olasılık modeli aynı olabilirlik fonksiyonuna sahip $p(y|\theta)$, θ için aynı çıkarımı sağlayarak olabilirlik ilkesi olarak isimlendirilmekte bu duruma uymaktadır (Gelman ve ark. 2004).

Olabilirlik ilkesi sadece model çerçevesi için ya da belirli bir analiz için benimsenmiş modellerin ailesi içinde mantıklıdır. Pratikte, seçilen modelin doğru model olduğuna nadiren emin olunabilir. Örneklem dağılımları model varsayımlarını kontrol ederken önemli bir rol oynayabilir. Aslında, Bayes teoremi ile ilgili uygulamalı istatistikçi çeşitli olası modellerin altında Bayes kuralını uygulamak için istekli olan kimsedir. Verilmiş bir model kapsamında θ_1 ve θ_2 noktalarında değerlendirilen sonsal yoğunluk $p(\theta|y)$ 'nin oranı θ_2 'ye göre θ_1 için sonsal olasılıklar olarak adlandırılır. Bu kavramın en çok benzeyen uygulaması kesikli parametreler ile, θ_2, θ_1 'in tamamlayıcısı olarak alınmasıdır. Oranlar olasılıkların alternatif gösterimini ve Bayes kuralının onların açısından ifade edildiğinde belirli basit bir biçim alan cazip özellik sağlar:

$$\frac{p(\theta_1|y)}{p(\theta_2|y)} = \frac{p(\theta_1)p(y|\theta_1)/p(y)}{p(\theta_2)p(y|\theta_2)/p(y)} = \frac{p(\theta_1) p(y|\theta_1)}{p(\theta_2) p(y|\theta_2)} \tag{2.31}$$

Yani sonsal oranlar, ilksel oranların olabilirlik oranı, $p(y|\theta_1) / p(y|\theta_2)$ ile çarpımına eşittir (Gelman ve ark. 2004).

Teorem 2.1 (Bayes Kuralı) :

$\{H_n\}$, $P H_n > 0$, $n = 1, 2, \dots$, ve $\sum_{n=1}^{\infty} H_n = \Omega$. gibi ayrık olaylar dizisi olsun. $P B > 0$ ile $B \in S$ olsun. Böylece,

$$P\{H_j|B\} = \frac{P(H_j)P\{B|H_j\}}{\sum_{i=1}^{\infty} P(H_i)P\{B|H_i\}}, \quad j=1,2,\dots \quad (2.32)$$

İspat 2.1

(Ω, S, P) bir olasılık uzayı olsun ve $P H > 0$ ile $H \in S$ olsun. Rastgele seçilmiş bir $A \in S$ için;

$$P\{A|H\} = \frac{P(A \cap H)}{P H} \quad (2.33)$$

Olarak yazılacak ve niceliği isimlendirme, verilen H için A koşullu olasılığı olarak tanımlanır. Koşullu olasılık $P H = 0$ olduğu zaman tanımsız kalır.

A ve B , $P A > 0$, $P B > 0$ ile iki olay olsun; Denklem (2.33)'den izlenerek;

$$P(A \cap B) = P A \cdot P\{B|A\} \text{ ve } P(A \cap B) = P B \cdot P\{A|B\} \quad (2.34)$$

Elde edilir. Denklem (2.34)' olayların her hangi bir rakamında genellenebilir:

$A_1, A_2, \dots, A_n \in S$, $n \geq 2$, olsun ve $P(\cap_{j=1}^{n-1} A_j) > 0$ olduğu varsayalım.

$$\begin{aligned} A_1 &\supset (A_1 \supset A_2) \supset (A_1 \supset A_2 \supset A_3) \supset \dots \\ &\dots \supset (\cap_{j=1}^{n-2} A_j) \supset (\cap_{j=1}^{n-1} A_j) \end{aligned} \quad (2.35)$$

$$P A_1 > 0, P(A_1 \cap A_2) > 0, \dots, P(\cap_{j=1}^{n-2} A_j) > 0 \quad (2.36)$$

Olduğu görülür. Bu iyi tanımlanmış $k=2, 3, \dots, n$. için

$P\{A_k | \cap_{j=1}^{n-1} A_j\}$ 'yi takip eder.

Denklem (2.34)'den (Rohatgi ve Saleh 2009)

$$P\{H_j|B\} = \frac{PH_jP\{B|H_j\}}{PB} \quad (2.37)$$

Böylece Teorem (2.1) ispat edilmiş olur. Sonuç şimdi Denklem (2.39)'u kullanarak ara vermeden devam eder.

H_1, H_2, \dots hepsi bir rastgele denemenin sonucuna yol açan nedenlerdir. H_j , j inci neden ile ilişkili sonuçların kümesi olsun. Olasıkların PH_j olduğu varsayalım, $j = 1, 2, \dots$ önsel olasıklar olarak adlandırılırlar ve atanabilirler. Pozitif olasılığın bir B olayındaki deneme sonuçları varsayalım. Bu bilgi önsel olasıkların yeniden değerlendirilmesine yol açar.

Koşullu olasıklar $P\{H_j|B\}$ sonsal olasıklar olarak adlandırılır. Denklem (2.32) gözlemlenen olay B, H_j nedeniyle ya da H_j hipotezi nedeniyle olasılığı veren bir kural olarak yorumlanabilir.

Teorem 2.2 (Çarpma Kuralı) :

(Ω, S, P) bir olasılık uzayı olsun ve $P(\bigcap_{j=1}^{n-1} A_j) > 0$ ile $A_1, A_2, \dots, A_n \in S$ olsun . O Halde

$$P(\bigcap_{j=1}^n A_j) = P(A_1)P\{A_2|A_1\}P\{A_3|A_1 \cap A_2\} \dots P\{A_n| \bigcap_{j=1}^{n-1} A_j\} \quad (2.38)$$

İspat 2.2

İspat basittir. $\{H_j\}$ 'in S'teki $H_j \cap H_k = \emptyset$, $j \neq k$ ve $\sum_{j=1}^{\infty} H_j = \Omega$ gibi sayılabilen ve toplanabilen olaylar olduğunu varsayalım. Tüm j için $PH_j > 0$ olduğu varsayalım. Böylece:

$$PB = \sum_{j=1}^{\infty} P(H_j)P\{B|H_j\} \quad \text{tüm } B \in S \text{ için} \quad (2.39)$$

İspat (2.2) için Denklem (2.40) dikkate alınmalıdır:

$$B = \sum_{j=1}^{\infty} (B \cap H_j) \quad (2.40)$$

Elde edilir. Denklem (2.39) toplam olasılık kuralı olarak adlandırılır

Bir Karar fonksiyonunun Bayes riski Denklem (2.41) tarafından tanımlanmıştır (Rohatgi ve Saleh 2009) :

$$R(\pi, \delta) = E_{\pi}R(\Theta, \delta) \quad (2.41)$$

Eğer Θ bir sürekli rastgele değişken (Random Variable) (RV) ve X sürekli biçimde ise, böylece:

$$\begin{aligned} R(\pi, \delta) &= \int R(\Theta, \delta)\pi(\theta)d\theta \\ &= \iint L(\Theta, \delta(x))f(x|\Theta)\pi(\Theta)dx d\Theta \\ &= \iiint L(\Theta, \delta(x))f(x, \Theta)dx d\Theta \end{aligned} \quad (2.42)$$

Eğer Θ olasılık kütle fonksiyonu π (PMF) ile kesikli ve X kesikli biçimde ise böylece:

$$R(\pi, \delta) = \sum_{\Theta} \sum_x L(\Theta, \delta(x))f(x, \Theta) \quad (2.43)$$

Diğer iki durumdaki benzer ifadeler yazılabilir.

Karar fonksiyonu δ^* bir Bayes kuralı ya da yöntemi olarak bilinir. Eğer karar fonksiyonu Bayes riskini en aza indirgerse, yani, eğer

$$R(\pi, \delta^*) = \inf_{\delta} R(\pi, \delta) \quad (2.44)$$

Rastgele değişkenin koşullu dağılımı Θ , verilmiş $X = x$, verilen örnekleme, Θ 'nın bir sonsal olasılık dağılımı, olarak isimlendirilir.

Birleşik PDF (PMF) Denklem (2.45)'deki biçimde ifade edilmiş olsun:

$$f(x, \Theta) = g(x)h(\Theta|x) \quad (2.45)$$

g , X 'in birleşik marjinal yoğunluk fonksiyonunu (PMF) göstermektedir. Bir ilksel PDF (PMF) $\pi(\Theta)$, Θ 'nın örneklemeden önceki dağılımını vermekte ve sonsal PDF (PMF) $h(\Theta|x)$, Θ 'nın örneklemeden sonraki dağılımını vermektedir. $h(\Theta|x)$ açısından Denklem (2.46) ve (2.47):

$$R(\pi, \delta) = \int g(x) \left[\int L(\Theta, \delta(x))h(\Theta|x)d\Theta \right] dx \quad (2.46)$$

veya

$$R(\pi, \delta) = \sum_x g(x) \left[\sum_{\Theta} L(\Theta, \delta(x))h(\Theta|x) \right] \quad (2.47)$$

(Rohatgi ve Saleh 2009)

f ya da π 'nin her ikisinde sürekli ya da her ikisinde kesikli olup olmadığına bağlı olarak yazılabilir.

Teorem 2.3

Karesel kayıp fonksiyonu $L(\theta, \delta) = (\theta - \delta)^2$ göre bir parametre $\Theta \in \theta \subseteq R$ 'nın kestiricisi problemi gözönüne alındığında Bayes çözümü ile verilir:

$$\delta(x) = E\{\theta|X = x\} \quad (2.48)$$

Denklem (2.48) tarafından tanımlanan $\delta(x)$, Bayes kestiricisi olarak isimlendirilir.

İspat 2.3

Süreklilik halinde, eğer π , Θ 'nın önsel PDF'i ise, böylece

$$R(\pi, \delta) = \int g(x) \{ \int [\theta - \delta(x)]^2 h(\theta|x) d\theta \} dx \quad (2.49)$$

Verilen x için; g , X 'in marjinal PDF'i ve h , Θ 'nin koşullu PDF'idir. Bayes kuralı $R(\pi, \delta)$ 'i minimize eden bir fonksiyon δ ' dir. $R(\pi, \delta)$ 'in minimizasyonu Denklem (2.50)'nin minimizasyonu ile aynıdır:

$$\int [\theta - \delta(x)]^2 h(\theta|x) d\theta \quad (2.50)$$

Sadece ve sadece:

$$\delta(x) = E\{\theta|x\} \quad (2.51)$$

Kalan durum için ispat benzerdir. Teorem 2.3'de kullanılan argümen bir Bayes kestiricisi $E\{L(\theta, \delta(X))|X\}$ 'yi minimize edenlerden birisi olduğunu göstermiştir. Teorem 1 eğer $L(\theta, \delta(X)) = [\theta - \delta(X)]^2$ ise özel bir durumdur. Fonksiyon:

$$\delta(x) = \int \theta h(\theta|x) d\theta \quad (2.52)$$

(Rohatgi ve Saleh 2009).

Denklem (2.52)'de Θ önsel dağılımı, π' ye göre Θ için Bayes kestiricisidir. $T(X)$ ' in parametre Θ için yeterli olduğu varsayılınsın. Bu durumda verilen x , Θ sonsal dağılımı yalnızca T vasıtasıyla x 'e bağlı olduğu kolayca görülmektedir. Ve Bayes kestiricisi Θ' nın T 'nin bir fonksiyonu olduğunu takip etmektedir.

Bayes teoremi ile ilgili bir bakış açısından $H_0: \theta \in \Theta_0$ hipotezine karşı $\mu_1: \theta \in \Theta_1$ hipotezi test etme problemi göz önüne alındığında, $\pi(\Theta)$, Θ dağılımında önsel olasılık olsun. Böylece:

$$\begin{aligned}
 R(\pi, \delta) &= E_{\theta} R(\theta, \delta(X)) \\
 &= \begin{cases} \int_{\theta} R(\theta, \delta) \pi(\theta) d\theta & \text{eğer } \pi \text{ bir PDF ise,} \\ \sum_{\theta} R(\theta, \delta) \pi(\theta) & \text{eğer } \pi \text{ bir PMF ise,} \end{cases} \\
 &= \begin{cases} \int_{\theta_0} b(\theta) \pi(\theta) P_{\theta} \{ \delta(X) = a_1 \} d\theta + \\ \int_{\theta_1} a(\theta) \pi(\theta) P_{\theta} \{ \delta(X) = a_0 \} d\theta & \text{eğer } \pi \text{ bir PDF ise,} \\ \sum_{\theta_0} b(\theta) \pi(\theta) P_{\theta} \{ \delta(X) = a_1 \} + \\ \sum_{\theta_1} a(\theta) \pi(\theta) P_{\theta} \{ \delta(X) = a_0 \} & \text{eğer } \pi \text{ bir PMF ise,} \end{cases} \quad (2.53)
 \end{aligned}$$

Bayes çözümü $R(\pi, \delta)$ 'yi minimize eden bir karar kuralıdır. Her iki H_0 ve H_1 'in her birisi tam olarak bir noktaya sahiptirler. Bu noktalar, $\Theta_0 = \{\theta_0\}$, $\Theta_1 = \{\theta_1\}$. $\pi(\theta_0) = \pi_0$ ve $\pi(\theta_1) = 1 - \pi_0 = \pi_1$ olsun. Böylece:

$$R(\pi, \delta) = b\pi_0 P_{\theta_0} \{ \delta(X) = a_1 \} + a\pi_1 P_{\theta_1} \{ \delta(X) = a_0 \}, \quad (2.54)$$

$$b(\theta_0) = b, a(\theta_1) = a; (a, b > 0)$$

Teorem 2.4

$X = (X_1, X_2, \dots, X_n)$, PMF(PDF) $f_{\theta}, \theta \in \theta = \{\theta_0, \theta_1\}$ ile kesikli (sürekli) biçiminin bir rastgele değişkeni (RV) olsun. $\pi(\theta_0) = \pi_0, \pi(\theta_1) = 1 - \pi_0 = \pi_1$, Θ önsel olasılık kütle fonksiyonu olsun. $H_0: X \sim f_{\theta_0}$ hipotezine karşı $H_1: X \sim f_{\theta_1}$ hipotezini test etmek için bir Bayes çözümü Denklem (2.55)'deki kayıp fonksiyonunu kullanır (loss function) (Rohatgi ve Saleh 2009).

$$\begin{cases} L(\theta, a_0) = a(\theta) & \text{eğer } \theta \in \theta_1, \quad a(\theta) > 0, \\ L(\theta, a_1) = b(\theta) & \text{eğer } \theta \in \theta_0, \quad b(\theta) > 0, \\ L(\theta, a_0) = 0 & \text{eğer } \theta \in \theta_0 \\ L(\theta, a_1) = 0 & \text{eğer } \theta \in \theta_1 \end{cases} \quad (2.55)$$

Kayıp fonksiyonunun Denklem (2.55)'deki gibi tanımlandığı varsayalım. H_0 hipotezi red edilir eğer:

$$\frac{f_{\theta_1}(x)}{f_{\theta_0}(x)} \geq \frac{b\pi_0}{a\pi_1} \quad (2.56)$$

İspat 2.4

δ değerini minimize yapılması istenmektedir. Denklem (2.54)

$$R(\pi, \delta) = b\pi_0 P_{\theta_0}\{\delta(X) = a_1\} + a\pi_1 P_{\theta_1}\{\delta(X) = a_0\} \quad (2.54)$$

Şu anda:

$$\begin{aligned} R(\pi, \delta) &= E_{\theta} R(\theta, \delta) \\ &= E\{E_{\theta}\{L(\theta, \delta)|X\}\} \end{aligned} \quad (2.57)$$

Böylece $E_{\theta}\{L(\theta, \delta)|X\}$ 'yi minimize yapmaya yeterli olmaktadır. θ 'nın bir sonsal dağılımı Denklem (2.58) tarafından verilmiştir:

$$\begin{aligned} h(\theta|x) &= \frac{\pi(\theta)f_{\theta}(x)}{\sum_{\theta} f_{\theta}(x)\pi(\theta)} \\ &= \frac{\pi(\theta)f_{\theta}(x)}{\pi_0 f_{\theta_0}(x) + \pi_1 f_{\theta_1}(x)} \\ &= \begin{cases} \frac{\pi_0 f_{\theta_0}(x)}{\pi_0 f_{\theta_0}(x) + \pi_1 f_{\theta_1}(x)} & \text{eğer } \theta = \theta_0 \text{ ise} \\ \frac{\pi_1 f_{\theta_1}(x)}{\pi_0 f_{\theta_0}(x) + \pi_1 f_{\theta_1}(x)} & \text{eğer } \theta = \theta_1 \text{ ise} \end{cases} \end{aligned} \quad (2.58)$$

Böylece (Rohatgi ve Saleh 2009):

$$E_{\theta}\{L(\theta, \delta(X))|X = x\} = \begin{cases} bh(\theta_0|x), & \theta = \theta_0, \delta(X) = a_1 \\ ah(\theta_1|x), & \theta = \theta_1, \delta(X) = a_0 \end{cases} \quad (2.59)$$

Bu nedenle H_0 hipotezi red edilir, yani, $\delta(X) = a_1$ eğer,

$$bh(\theta_0|x) \leq ah(\theta_1|x), \quad (2.60)$$

Sadece ve sadece

$$b\pi_0 f_{\theta_0}(x) \leq a\pi_1 f_{\theta_1}(x), \quad (2.61)$$

iddia edildiği gibi.

Kabul edilmiş Neyman-Pearson teoreminde $P_{\theta_0}\{\delta(X) = a_1\}$ sabitlenmiştir.

H_0 hipotezi doğru iken H_0 hipotezini red etme olasılığı ve minimize edilmiş $P_{\theta_1}\{\delta(X) = a_0\}$, H_0 hipotezini yanlış iken kabul etme olasılığı. $P_{\theta_0}\{\delta(X) = a_1\}$ için α seviyesinde daha fazla sabitlenmemiştir. Bunun yerine Denklem (2.54)'de minimum olarak tanımlandığı sürece $R(\pi, \delta)$ ' in herhangi değer aldığı varsayımına izin verilmiştir.

Teorem (2.4)'ü çoklu kararların olduğu durumlarda genelleştirmek kolaydır. X , PDF (PMF) f_{θ} ile Θ 'nın herhangi k değerleri $\theta_1, \theta_2, \dots, \theta_k$ alabileceği bir RV olsun. Problem x 'i gözlemlemek ve Θ 'nın doğru değerine θ_i 'lerden hangisi olduğuna karar vermektir. $H_i: \theta = \theta_i, i = 1, 2, \dots, k$, yazılsın ve varsayılsın ki: $\pi(\theta_i) = \pi_i, i = 1, 2, \dots, k, \sum_1^k \pi_i = 1, \Theta = \{\theta_1, \theta_2, \dots, \theta_k\}$ dağılımında önsel olasılıktır.

$$L(\theta_i, \delta) = \begin{cases} 1 & \text{eğer } \delta, \theta_j'yi \text{ seçerse, } j \neq i \\ 0 & \text{eğer } \delta, \theta_i'yi \text{ seçerse} \end{cases} \quad (2.62)$$

Bu durumda Bayes çözümü $H_i: \theta = \theta_i (i = 1, 2, \dots, k)$, eğer:

$$\pi_i f_{\theta_i} \geq \pi_j f_{\theta_j}(x) \quad \text{tüm } j \neq i, j = 1, 2, \dots, k; \text{ için} \quad (2.63)$$

ise, birden fazla böyle bir bölgede yer alan herhangi bir nokta herhangi birine atanmış ise, $H_i: \theta = \theta_i$ kabul eder (Rohatgi ve Saleh 2009).

Bölüm 2.2.2.1. En Çok Olabilirlik Kestiricisi ve Sınıflandırması, başlığındaki Şekil (2.30)'da değinilen orman ve tarım sınıfları ile ilgili örneği yukarıda teorik yapısının açıklandığı şekilde Bayes sınıflandırıcısı açısından bakıldığında:

Sınıflandırma problemi, tahmin edilmesi istenilen, orman sınıfına ait olasılık, gözlemlenmiş sayısal değer olarak 45 verilmiş ve tarım sınıfına ait olasılık gözlemlenmiş değer olarak yine 45 olarak verilerek ifade edilip daha fazla biçimsel olarak açıklanabilir. Bu ifadeler koşullu olasılıkların bir biçimi olup, $P(O|45)$ ve $P(T|45)$ şeklinde yazılıp, orman sınıfı ile karşılaşma olasılığı, varsayımsal olarak bir pikselde gözlemlenmiş sayısal değer 45 olarak okunur. Bu bir olayın olasılığının ifade edilmesidir (bir pikselde verilen bir sınıfın bulunması). Varsayımsal başka bir olay zaten meydana gelmiştir (aynı pikselde sayısal değer 45'in gözlemlenmesi). Oysa rastgele (koşullu bir kısıtlama olmaksızın) iki sınıfta karşılaşma olasılıklarının tahmini apaçıktır (burada yukarıda bahsedildiği gibi $P[O] = 0.50$ ve $P[T] = 0.50$ 'dir). Koşullu olasılıklar iki ayrı olayı esas alır. İki sınıf için tahmin edilen ön bilgilendirme verilerinden, $P(45|O)$ tahmin edilebilir (sayısal değer 45 ile karşılaşma olasılığı varsayımsal olarak orman sınıfı olması) ve $P(45|T)$ (sayısal değer 45 ile karşılaşma olasılığı varsayımsal olarak tarım sınıfı olması) bu örnek için, $P(45|O) = 0.75$ ve $P(45|T) = 0.25$ 'dir. Buna rağmen, bilinmesi istenilen orman sınıfı için varsayımsal gözlemlenmiş sayısal değer 45, $[P(O|45)]$ ve tarım, varsayımsal gözlemlenmiş sayısal değer 45, $[P(T|45)]$ için olasılık değerleridir. Böylece piksel için en çok olabilirlik sınıfı seçimi karşılaştırılabilir. Bu olasılıklar ön bilgilendirme verilerinden doğrudan bulunamaz. Problemin sadece bir sezgisel incelemesinden, bu olasılıkların tahminine ilişkin herhangi bir yol gözükmemektedir (Campbell ve Wynne 2011).

Fakat, aslında eldeki bilgilerden $P(45|O)$ ve $P(45|T)$ 'i tahmin için bir yol vardır. Thomas Bayes (1702-1761), bilinmeyen $P(45|O)$ ve $P(45|T)$ ile bilinen $P(O)$, $P(T)$, $P(45|O)$ ve $P(45|T)$ arasındaki ilişkiyi tanımlamıştır. Bayes'in ilişkisi şu anda Bayes teoremi (Bayes's theorem) olarak bilinmekte ve bu örnek için aşağıdaki gibi ifade edilmektedir:

$$P(O|45) = \frac{P(O)P(45|O)}{P(O)P(45|O) + P(T)P(45|T)} \quad (2.64)$$

$$P(T|45) = \frac{P(T)P(45|T)}{P(T)P(45|T) + P(O)P(45|O)} \quad (2.65)$$

Daha genel bir biçimde, Bayes teoremi aşağıdaki gibi yazılabilir:

$$P(b_1|a_1) = \frac{P(b_1)P(a_1|b_1)}{P(b_1)P(a_1|b_1) + P(b_2)P(a_1|b_2) + \dots} \quad (2.66)$$

Denklem (2.66)'da a_1 ve a_2 deneyin ilk aşamasının alternatif sonuçlarını temsil etmekte ve b_1 ve b_2 ikinci aşama için alternatif sonuçları temsil etmektedir. İlgili örnek için, Bayes teoremi aşağıdaki şekilde uygulanabilir:

$$\begin{aligned} P(O|45) &= \frac{P(O)P(45|O)}{P(O)P(45|O) + P(T)P(45|T)} \quad (2.64) \\ &= \frac{\frac{1}{2} \times \frac{3}{4}}{(\frac{1}{2} \times \frac{3}{4}) + (\frac{1}{2} \times \frac{1}{4})} = \frac{\frac{3}{8}}{\frac{4}{8}} = \frac{3}{4} \end{aligned}$$

$$\begin{aligned} P(T|45) &= \frac{P(T)P(45|T)}{P(T)P(45|T) + P(O)P(45|O)} \quad (2.65) \\ &= \frac{\frac{1}{2} \times \frac{1}{4}}{(\frac{1}{2} \times \frac{1}{4}) + (\frac{1}{2} \times \frac{3}{4})} = \frac{\frac{1}{8}}{\frac{4}{8}} = \frac{1}{4} \end{aligned}$$

Böylece bu pikselin orman sınıfına ait olması tarım sınıfına ait olmasından daha fazla olası olduğuna karar verilir (Campbell ve Wynne 2011).

Genellikle birkaç spektral kanal için veriler düşünüldüğünde ve genellikle ikiden daha fazla sınıflardan seçim yapılması istenildiğinde bu örnek fazlasıyla sadeleştirilir. Gerekli olabilecek kadar birçok bant ya da bir çok sınıf için, ifadeler burada tartışıldığından daha fazla karmaşık olsa bile bu süreç genişletilebilir. Uzaktan algılama sınıflandırması için, Bayes teoreminin uygulaması, sınıflar belirsiz olduğunda ya da spektral veri uzayında üst üste binme durumları olduğunda özellikle etkilidir. Aynı zamanda, ilave bilginin koşullu olasılık olarak ifade edilebilmesi gibi sınıflandırma içerisine ikincil verileri dahil etmek için uygun bir araç biçimidir. İlâveten analiz içerisinde yanlış sınıflandırma maliyetlerini tanıtmamanın bir yolunu sağlayabilir. (Belki orman sınıfına bir pikselin yanlış atanması hatası, tarım sınıfına yanlış atanmasından daha ciddidir.)

Daha da ötesi, Bayes teoremi ile diğer sınıflandırma süreçleri birleştirilebilir, böylece örneğin, piksellerin bir çoğu bir paralelyüzlü sınıflandırıcı kullanılarak atanabilir ve daha sonra Bayes teoremi ile ilgili sınıflandırıcı karar sınırının içerisinde yer almayan ya da üst üste binme bir bölgesi içerisinde yer alan bu pikseller için kullanılabilir. Bazı çalışmalar bu tür sınıflandırıcıların çok doğru olduğunu göstermiştir (Story ve ark. 1984'den akt. Campbell ve Wynne 2011).

Böylece Bayes teoremi, eldeki bilgileri kullanarak önceden gelen olayların ortaya çıkmasında ilgili olan sonuçların olasılıklarını tahmin etmede, son derece güçlü bir araçtır. Bayes teoremi ile ilgili yaklaşımla sınıflandırmanın zayıf noktası ön bilgilendirme (eğitim) verilerinin seçimidir. Eğer olasılıklar kesin ise, Bayes stratejisi gözlemlerin sınıflara etkili atamalarını vermelidir. Şüphesiz, sadece sayısal bakış açısından, süreç herhangi bir değer ile cevap verecektir. Fakat kesin sınıflandırmadan emin olmak için, ön bilgilendirme verileri temsil ettikleri sınıfların ilişkine güvenilir bir şekilde sahip olmalıdır. Çok boyutlu durum için, bir kaç spektral bant ile, her bir bantın değişkenliğini ve diğer bantlar ile ilişkilerini özetlemek için her bir sınıf için, her bir bant ve varyans-kovaryans matrisi için ortalama parlaklığı tahmin etmek gerekir (Campbell ve Wynne 2011).

Bu verilerden, tüm sınıfların ortalamaları, varyansları, ve kovaryansları tahmin edilerek bilinmeyene ulaşılır. Genellikle bu bilinmeyene dayanan kestirim bazında üretilen veriler çok değişkenli normal frekans dağılımları ile karakterize olmuştur. Eğer bu tür varsayımlar gerekçeli değilseler, sınıflandırma sonuçları doğru olmayabilir. Eğer sınıflar ve alt sınıflar mantıklı bir şekilde seçilmiş ise ve eğer ön bilgilendirme verileri doğru ise, sınıflandırmaya Bayes yaklaşımı, uygulanabilen herhangi birisi kadar etkili olmalıdır. Eğer sınıflar yetersiz tanımlanmış ve ön bilgilendirme verisi eşleştiği sınıfları temsil etmiyorsa, daha sonra sonuçlar benzer şartlar altında uygulanan diğer sınıflandırıcılar için daha iyi değildir. Sınıflandırma biçimlerinde Bayes yaklaşımının kullanımı güçlü bir strateji oluşturur, sınıfların ilişkili çeşitliliğine ilişkin bilginin içerilmesinin yanı sıra ortalamalar ve aralıklar daha önceki sınıflandırma stratejelerinde kullanılmışlardır. Buradaki basit örnek, sadece tek bir veri kanalı ve sadece iki sınıf arasında bir seçim esas alınarak kullanılmıştır (Campbell ve Wynne 2011).

Aynı yaklaşım verilerin bir kaç bantı ve birkaç sınıf kümeleri için genişletilerek düşünülebilir. Bu sınıflandırma yaklaşımı son derece kullanışlı ve esnek olmakla birlikte, kesin şartlar altında, verilen ön bilgilendirmeli sınıflandırmanın kısıtlamalarının en çok etkili aracının büyük bir olasılıkla ne olduğunun bilinmesini sağlar. Dikkat etmek gerekirse buna rağmen, pek çok uygulamada, bu strateji sınıflandırma için gerekli olan olasılıkların tahminlerinin kalitesi tarafından sınırlandırılmıştır; eğer bunlar doğru ise, sonuçlar en iyi sınıflandırmayı sağlayabilir; eğer onlar geçici çözüm değerleri hesaplama için basit bir şekilde sayıları sağlamayı akla getiriyor ise, bu sonuçlar ciddi kusurlara sahip olabilir (Campbell ve Wynne 2011).

Eğer tüm sınıflar için olasılıkların eşit olmadığı önsel bilgisi mevcut ise, belirli sınıflar için ağırlık faktörleri belirtilebilir. En çok olabilirlik karar kuralının bu çeşitliliği Bayes teoremi ile ilgili karar kuralı olarak bilinmektedir (Hord 1982'den akt. Anonim, 1999). Olasılıkların önsel bir bilgisine sahip olunmadıkça, belirlenmiş olmadıkları tavsiye edilmiştir. Bu durumda bu ağırlıklar denklem içerisinde 1.0 oldukları varsayılacaktır. En çok olabilirlik / Bayes teoremi ile ilgili sınıflandırıcı aşağıda verilmiştir (Anonim, 1999):

$$D = \ln(a_c) - [0.5 \ln(|Cov_c|)] - [0.5(X - M_c)T(Cov_c - 1)(X - M_c)] \quad (2.67)$$

Denklem (2.67)'deki simgelerin anlamları aşağıdadır:

D = ağırlıklandırılmış uzaklık (olabilirlik)

c = belirli bir sınıf

X = aday pikselin ölçüm vektörü

M_c = sınıf c örnekleminin ortalama vektörü

a_c = herhangi aday pikselin sınıf c 'nin bir üyesi olmasının yüzdesel olasılığı
(1.0 olduğu varsayılmaktadır ya da önsel bir bilgiden girilen değerdir)

Cov_c = sınıf c 'nin örnekleminin içerisindeki piksellerin kovaryans matrisi

$|Cov_c|$ = Cov_c 'nin determinanı (matris cebiri)

$Cov_c - 1$ = Cov_c 'in tersi (matris cebiri)

\ln = doğal logaritma fonksiyonu

T = yer değiştirme fonksiyonu (transposition function) (matris cebiri)

Bir matrisin tersi ve determinanı, vektörlerin farkı ve yer değiştirmesi ile birlikte matris cebiri ders kitaplarında mevcuttur. Denklem (2.67)'ye göre sınıf

c'ye atanan piksel için D en düşük değeri alır. En çok olabilirlik / Bayes teoremi ile ilgili olan karar kuralına ait avantajlar şu şekildedir: Erdas Imagine sisteminde girdi örneklemeleri ya da kümeleri normal bir dağılıma sahip ise en fazla doğruluğa sahip sınıflandırıcıdır. Bunun nedeni çoğu değişkenleri göz önüne almasıdır. Mahalanobis uzaklığının yaptığı gibi kovaryans matrisi kullanarak sınıfların değişkenliklerini hesaba katar.

En çok olabilirlik / Bayes teoremi ile ilgili olan karar kuralına ait dezavantajlar şu şekildedir: Kapsamlı bir denklem hesaplama için çok zaman alır. Hesaplama zamanı girilen bant sayısının artması ile artar. En çok olabilirlik parametrikdir. Bunun anlamı her bir giriş bantındaki verilerin normal bir dağılımına aşırı derecede güvenmesidir (Anonim, 1999).

Kovaryans matrisi içindeki diğerlerine göre büyük değerler ile imzalar üst üste sınıflandırma eğilimindedir. Eğer bir küme içerisinde ya da ön bilgilendirme örneklemindeki piksellerin geniş dağılımı varsa, böylece kovaryans matrisinin imzası büyük değerler içerir (Anonim, 1999).

2.3. EM Algoritması

Beklenti en büyükleme algoritması ya da beklenti maksimizasyonu algoritması (EM Algorithm), en çok olabilirlik (ML) kestiricilerinin yinelemeli hesaplamasına geniş olarak uygulanabilir bir yaklaşımdır. Çok karmaşık olduğu anlaşılan Newton-Raphson metodu gibi algoritmaların eksik veri problemleri çeşitliğinde kullanışlıdır. EM algoritmasının her bir yinelemesinde, iki adım vardır. Bu adımlar: Beklenti adımı ya da E-Adımı ve en büyükleme adımı ya da M-Adımı olarak adlandırılırlar. Bu yüzden dolayı algoritma EM algoritması olarak adlandırılır. Bu isim Dempster, Laird ve Rubin (1977) tarafından temel makalelerinde verilmiştir. Bu yüzden bundan sonra bu makaleye kısaca DLR makalesi ya da basitçe DLR denilecektir. ML tahmini, çok benzer ve daha basit veri yapısı içerisindeki verilerin bazı kısımlarının yokluğu tarafından zorlaştırılan eksik veri problemlerinde olduğu gibi EM algoritması kazançlı bir şekilde uygulanan durumlar olarak tarif edilebilir. Parametreleri eksik veriler için ilk ya da başlangıç değerleri doldurulduktan sonra tahmin edilen EM algoritması eksik veriler ile tahmin için özel bir amaçlı yaklaşımla yakından ilgilidir (McLachlan ve Krishnan 2008).

İkinci olarak daha sonra bu ilk parametre tahminleri kullanılarak parametre tahminleri güncellenir. Parametreler daha sonra tekrar tahmin edilir ve benzeri şekilde yakınsamaya kadar yineleme tekrar eder. EM gibi sezgisel ve doğal olan algoritmalar arkasındaki bu fikir, DLR makalesinden önce bile, formüle edilmiş ve çeşitli problemlere uygulanmıştır (McLachlan ve Krishnan 2008).

Fakat fikirleri sentezleyerek yeni ufuklar açmış DLR makalesi, EM algoritmasının genel bir formülasyonunu resmileştirmiş, özellikleri incelenmiş ve geleneksel ve geleneksel olmayan uygulamaları belirtip bu uygulamaları ağırlamıştır. EM algoritmasına uygulanabilir durumlar sadece açık bir şekilde var olan eksik verileri, köreltilmiş dağılımları, sansürlenmiş ya da gruplanmış gözlemlerdeki eksik veri durumlarını içermez aynı zamanda verilerin eksikliklerinin tamamı doğal ya da belirgin olmadığı bütün bir çeşitlilik durumunu içerir. Rastgele etkiler, karmalar, evrişimler, log doğrusal modeller, gizli (latent) sınıfı ve gizli değişken yapısı gibi istatistiksel modelleri içerir. Bu durumlar için şimdiye dek inatçı olan ML tahmin problemleri çözülmüş ya da karmaşık ML tahmin süreçleri EM algoritması kullanılarak basitçe indirgenmiştir. EM algoritması böylece hemen hemen tüm istatistiksel bağlamlarda ve istatistiksel tekniklerin uygulandığı; tıbbi görüntüleme, günlük hayvan ürünleri ile ilgili bilimsel alanda, olması gerektiğinden eksik nüfus sayımın düzeltilmesi ve AIDS salgın hastalıkları bilimi gibi birkaçından bahsedilen hemen hemen tüm alanlarda uygulamalar bulmaya sahip olmuştur.

Karmaşık olabilirlik fonksiyonlarında sonuçları bulunan; eksik değerli veri setleri, sansürlenmiş ve gruplandırılmış gözlemler ve köreltilmiş dağılımlı modeller ve benzeri gibi örnekler pratik durumlardan kaçınmazlar. EM algoritmasının gelişimi ve ilişkili metodoloji ile birlikte ucuz kullanılabilirliği ve hızlı hesaplama gücü daha önce olduğundan çok daha işlenebilir biçimde veri setlerinin analizlerini yapmıştır. EM algoritması istatistiksel repertuvarda zaten bir standart araç haline gelmiştir. EM algoritmasının temel fikri, ML tahminin sayısal olarak daha işlenebilir olması durumu için verilmiş olan tamamlanmamış veri problemi, tamamlanmış veri problemi ile ilişkilidir. Örnek vermek gerekirse, seçilmiş tamamlanmış veri problemi, en çok olabilirlik tahmini kapalı bir biçimde çözüm için ürün verebilir ya da standart bilgisayar paket programı ile MLE hesaplaması makul olabilir (McLachlan ve Krishnan 2008).

EM algoritmasının metodolojisi sonra, bu daha çok kolay çözülmüş eksiksiz tamamlanmış veri problemi açısından problemi tekrar formüle etmeden meydana gelmiştir. Bu iki problemin olabirlikleri arasında bir ilişki kurar ve yinelenen hesaplama algoritmasının M-adımında tamamlanmış veri probleminin daha basit MLE hesaplar ve faydalanır.

İlk bakışta bir problem eksik veri olarak görülmesede ML tahminin kolaylaştırmak gibi çok yapay formüle ederek akıllıca hesap kazancı sağlayabilir. Bunun nedeni EM algoritmasının verilmiş eksiksiz verilerin ML tahminlerinin karmaşıklığının indirgeyerek fayda sağlamasıdır. Bir çok istatistiksel problemler, eksiksiz veriler olabirliği güzel bir biçime sahiptir. E-adımı eksiksiz veri problemi için üretim verileri içerir. Eksik veri probleminin gözlemlenmiş veri kümesini ve parametrelerin güncel değerlerini kullanır böylece daha basit M-adımı hesaplaması bu eksiksiz veri kümesine uygulanabilir. Daha kesin olarak, eksiksiz veri problemi E-adımında üretilen eksiksiz veri probleminin log olabirliğidir (log likelihood). Kısmi olarak gözlemlenmemiş veriler temel olarak, bu E-adımı bilinmeyen parametreler için geçerli bir ayarlamayı kullanarak gerçekleştiren verilmiş gözlemlenmiş değerlerin koşullu beklentisi tarafından yerine konulmuşlardır. Uygun ilk parametre değerlerinden başlayarak, E- ve M-adımları yakınsama olasıya kadar tekrarlanır. Şüphesiz eksiksiz veri problemi, MLE'nin eksiksiz verilerinin basitleştirilmesinin bakış açısından uygun seçilmiş olmalıdır. Pratik uygulamanın bakış açısından bir varsayımsal problem bile olabilir. Örneğin, bir eksiksiz veri problemi gözlemlenmemiş gizli değişkenleri üzerindeki verilere sahip faktör analizinin içeriğinde tanımlanmıştır.

EM algoritması çeşitli şartlara başarılı bir şekilde uygulanmış olmasına rağmen, belirli durumlarda yakınsama ızdıraplı bir şekilde yavaş olabilir. Bu durum, algoritmanın değiştirilmiş sürümlerinin yanı sıra çok sayıda simülasyon tabanlı metotlar ve diğer uzantılarının gelişmesine neden olmuştur. Bu alan hala gelişmektedir. EM algoritmasının bir ilk eleştirisi MLE'nin kovaryans matrisinin tahminlerini üretilmemiş olmasıdır. Buna rağmen, daha sonra gelen gelişmelerde DLR makalesinde bu gibi tahmin için EM hesaplama düzeni içine entegre edilebilir metotları sağlamıştır (McLachlan ve Krishnan 2008).

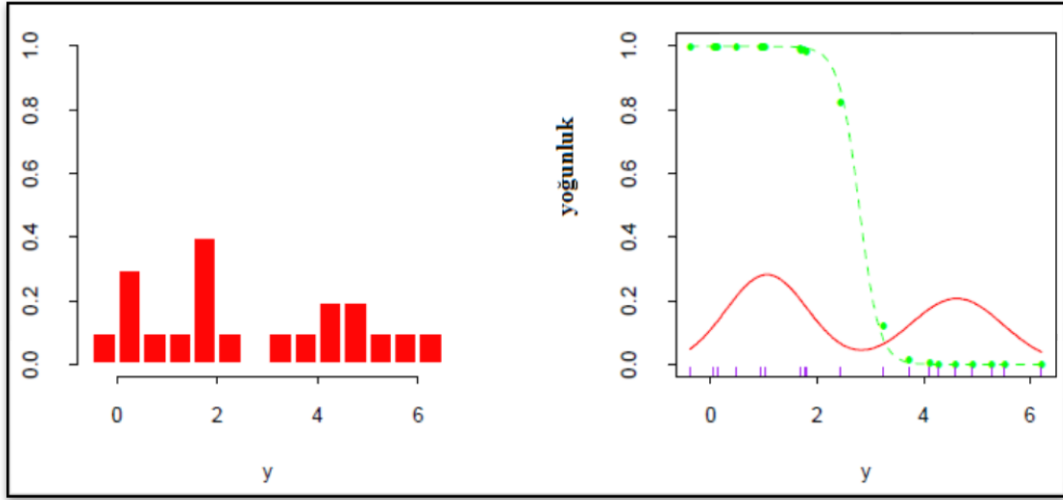
2.3.1. İki Bileşenli Karma Model

Şekil (2.31)'in sol panelinde (a) Çizelge (2.4)'deki 20 varsayımsal veri noktasının bir histogramını göstermektedir. Veri noktalarının yoğunluğu modellenmek istenildiğinden ve belirgin iki mod durumundan dolayı, Gauss dağılımı uygun olmaz. Temelde yatan iki ayrı rejim gibi gözükmekte olduğu için, Y iki normal dağılımın bir karması gibi modellenir:

$$Y_1 \sim N(\mu_1, \sigma_1^2)$$

$$Y_2 \sim N(\mu_2, \sigma_2^2)$$

$$Y = (1 - \Delta).Y_1 + \Delta.Y_2 \quad (2.68)$$



(a)

(b)

Şekil 2.31. Karma örnek. Verilerin histogramı (a). Gauss yoğunluklarının en çok olabilirlik uygunluğu (b) (kırmızı) ve y 'nin bir fonksiyonu gibi gözlem y için sol bileşenin yoğunluğunun yükümlülüğü (noktalı yeşil) (Hestie ve ark. 2008)

Çizelge 2.4. Şekil 2.31'deki iki bileşenli karma örneğinde kullanılan yirmi varsayımsal veri noktaları (Hestie ve ark. 2008)

-0.39	0.12	0.94	1.67	1.76	2.44	3.72	4.28	4.92	5.53
0.06	0.48	1.01	1.68	1.80	3.25	4.12	4.60	5.28	6.22

$\Delta \in \{0,1\}$, $\Pr(\Delta=1) = \pi$. Bu üretken simgeleme açıktır: olasılık π ile bir $\Delta \in \{0,1\}$ oluşturmak ve sonrasında sonuçlara bağlı olarak her iki Y_1 ya da Y_2 'ye dağıtmak. $\phi_\theta(x)$, parametreleri $\theta = (\mu, \sigma^2)$ ile normal yoğunluğu gösterebilir. Daha sonra Y 'nin yoğunluğu:

$$g_y(y) = (1 - \pi)\phi_{\theta_1}(y) + \pi\phi_{\theta_2}(y) \quad (2.69)$$

Şekil (2.31)'deki verileri bu modeli en çok olabilirlik tarafından uydurulmak istenildiği varsayalım. Parametreler:

$$\theta = (\pi, \theta_1, \theta_2) = (\pi, \mu_1, \sigma_1^2, \mu_2, \sigma_2^2) \quad (2.70)$$

N ön bilgilendirme durumu esas alınarak log-olabilirlik :

$$l(\theta; Z) = \sum_{i=1}^N \log [(1 - \pi)\phi_{\theta_1}(y_i) + \pi\phi_{\theta_2}(y_i)] \quad (2.71)$$

Sayısal olarak $l(\theta; Z)$ 'nin doğrudan en büyükleme terimler toplamı logaritmanın içerisinde olduğu için oldukça zordur. Buna rağmen basit bir yaklaşım vardır. Gözlemlenmemiş gizli değişkenler Δ_i olarak düşünülün ve Denklem (2.68)'deki gibi 0 ya da 1 değerlerini alsın. Eğer $\Delta_i = 1$ ise böylece Y_i model 2'den gelir, aksi takdirde model 1'den gelir. Δ_i 'lerin değerlerinin bilindiği varsayalım. Böylece log-olabilirlik:

$$l_0(\theta; Z, \Delta) = \sum_{i=1}^N [(1 - \Delta_i) \log \phi_{\theta_1}(y_i) + \Delta_i \log \phi_{\theta_2}(y_i)] \\ + \sum_{i=1}^N [(1 - \Delta_i) \log(1 - \pi) + \Delta_i \log \pi] \quad , \quad (2.72)$$

ve μ_1 ve σ_1^2 en çok olabilirlik tahminleri, $\Delta_i = 1$ olan bu veriler için, örneklem ortalaması ve varyansı olurken, benzer şekilde μ_2 ve σ_2^2 , $\Delta_i = 1$ olan verilerde örneklem ortalaması ve varyansı olur. π 'nin tahmini $\Delta_i = 1$ 'nin oranı π 'nin tahmini olacaktır. Δ_i 'nin değerleri aslında bilinmediği için, yinelemeli tarzda devam edilirse, her bir Δ_i için Denklem (2.72)'de yerine konulduğunda, beklenen değeri:

$$\gamma_i(\theta) = E(\Delta_i | \theta, Z) = \Pr(\Delta_i = 1 | \theta, Z), \quad (2.73)$$

(Hestie ve ark. 2008).

Aynı zamanda, i . gözlem için model 2'nin yükümlülüğü olarak adlandırılır. EM algoritması olarak adlandırılan süreç kullanılacaktır. Algoritma (2.1)'de verilmiş olan bu süreç, Gauss karmanın özel bir durumudur. Beklenti adımı yani E-adımında, her bir modele her bir gözlemin yumuşak atamaları yapılır: Parametrelerin mevcut tahminleri, her bir modelin altındaki ön bilgilendirme noktalarının göreceli yoğunluklarına göre yükümlülük ataması kullanılarak yapılmıştır. En büyükleme adımı ya da M-adımında ağırlıklandırılmış en çok olabilirlikte kullanılan bu sorumluluklar parametrelerin tahminlerini güncellemek için uygundur.

$\hat{\mu}_1$ ve $\hat{\mu}_2$ için ilksel ya da ilk tahminleri yapmanın iyi bir yolu, basitçe rastgele bir şekilde y_i 'den iki seçim yapmaktır. Her iki $\hat{\sigma}_1^2$ ve $\hat{\sigma}_2^2$, tüm örneklem varyansına $\sum_{i=1}^N (y_i - \bar{y})^2 / N$, eşit olarak ayarlanabilir. Karma oranı $\hat{\pi}$, 0.5 değerinden başlatılabilir.

Olabilirliğin asıl en büyüklemesi, her hangi bir veri noktasında sonsuz yükseklikte bir ani yükseliş konulduğunda oluşur. Bu bazı i ve $\hat{\sigma}_1^2$ için $\hat{\mu}_1 = y_i$ 'dir. Bu sonsuz olabilirliği verir, fakat kullanışlı bir çözüm değildir. Bu yüzden dolayı aslında olabilirliğin iyi bir lokal en büyüklemesi bakılmaktadır. Birisi için; $\hat{\sigma}_1^2, \hat{\sigma}_2^2 > 0$. Daha da fazla karmaşık sorunlar, birden fazla lokal en büyükleme sahip olan $\hat{\sigma}_1^2, \hat{\sigma}_2^2 > 0$ olabilir. Verilen örnekte EM algoritması, hepsi $\hat{\sigma}_k^2 > 0.5$ olan parametreler için farklı ilksel tahminleri ile çalıştırılır ve çalıştırmak için yapılacak seçimler en çok olabilirliği verecek şekilde seçilirler. Şekil (2.32) log-olabilirliği en büyüklüyen EM algoritmasının sürecini göstermektedir. Çizelge (2.5), EM yönteminin seçilmiş yinelemelerinde, sınıf 2 gözlemlerinin oranlarının en çok olabilirlik tahminlerini $\hat{\pi} = \sum_i \hat{Y}_i / N$, göstermektedir. Şekil (2.31)'in sağ paneli olan (b) bu süreçten (kırmızı eğri) yükümlülükler ile birlikte (noktalı yeşil eğri), tahmin edilmiş Gauss karma yoğunluğu göstermektedir (Hestie ve ark. 2008).

Algoritma 2.1. İki Bileşenli Gauss Karma Model İçin EM Algoritması

1. $\hat{\mu}_1, \hat{\sigma}_1^2, \hat{\mu}_2, \hat{\sigma}_2^2, \hat{\pi}$ parametreleri için ilk tahminlerin yapılması
2. Beklenti Adımı (Expectation Step): Yükümlülüklerin Hesaplanması

$$\hat{\gamma}_i = \frac{\hat{\pi}\phi_{\hat{\theta}_2}(y_i)}{(1-\hat{\pi})\phi_{\hat{\theta}_1}(y_i)+\hat{\pi}\phi_{\hat{\theta}_2}(y_i)} \quad , \quad i = 1, 2, \dots, N. \quad (2.74)$$

3. En Büyükleme Adımı (Maximization Step): Ağırlıklandırılmış ortalamaların ve varyansların hesaplanması

$$\hat{\mu}_1 = \frac{\sum_{i=1}^N (1-\hat{\gamma}_i)y_i}{\sum_{i=1}^N (1-\hat{\gamma}_i)} \quad , \quad (2.75)$$

$$\hat{\sigma}_1^2 = \frac{\sum_{i=1}^N (1-\hat{\gamma}_i)(y_i-\hat{\mu}_1)^2}{\sum_{i=1}^N (1-\hat{\gamma}_i)} \quad , \quad (2.76)$$

$$\hat{\mu}_2 = \frac{\sum_{i=1}^N \hat{\gamma}_i y_i}{\sum_{i=1}^N \hat{\gamma}_i} \quad , \quad (2.77)$$

$$\hat{\sigma}_2^2 = \frac{\sum_{i=1}^N \hat{\gamma}_i (y_i-\hat{\mu}_2)^2}{\sum_{i=1}^N \hat{\gamma}_i} \quad , \quad (2.78)$$

ve karma olasılığı :

$$\hat{\pi} = \frac{\sum_{i=1}^N \hat{\gamma}_i}{N} \quad (2.79)$$

4. Adım 2 ve 3 yakınsama olasıya kadar yinelenir.

(Hestie ve ark. 2008).

Çizelge 2.5. Karma örneği için EM algoritmasının seçilmiş yinelenmeleri (Hestie ve ark. 2008)

Yineleme	$\hat{\pi}$
1	0.485
5	0.493
10	0.523
15	0.544
20	0.546

En son, en çok olabilirlik tahminleri:

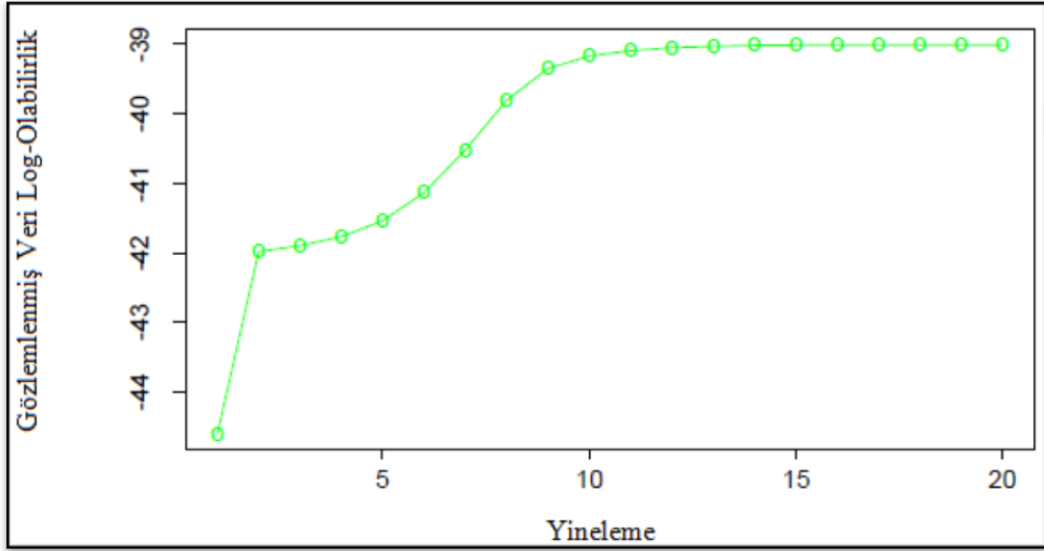
$$\hat{\mu}_1 = 4.62$$

$$\hat{\sigma}_1^2 = 0.87$$

$$\hat{\mu}_2 = 1.06$$

$$\hat{\sigma}_2^2 = 0.77$$

$$\hat{\pi} = 0.546$$



Şekil 2.32. EM Algoritması: Yineleme sayısının bir fonksiyonu gibi gözlemlenmiş veri log-olabilirlik (Hestie ve ark. 2008)

2.3.2. Genel EM Algoritması

Bir önceki kısımda anlatılan iki bileşenli karma model süreci EM (ya da Baum-Welch) algoritmasının belirli bir sınıf probleminde en çok olabilirlik için bir örneğidir. Bu problemler olabilirliğin en büyüklemesi zor olan fakat, gizli, (gözlemlenmemiş) ile büyümekte olan olan örneklem tarafından kolaylaştırılan veriler içindir. Bu veri artışı olarak adlandırılır. Burada gizli veriler model üyeliği Δ_i 'lerdir. Diğer problemlerde, gizli veriler gözlemlenmiş olması şart fakat eksik olan asıl verilerdir. Algoritma (2.2) EM algoritmasının genel formülasyonunu vermektedir. Gözlemlenmiş veriler Z , log-olabilirliğe sahip $l(\theta; Z)$ parametreler θ 'ya bağlıdır. Gizli ya da kayıp veriler Z^m 'dir. Böylece tüm veriler log-olabilirlikle $l_0(\theta; T)$ birlikte $T = (Z, Z^m)$ 'dir. l_0 tam yoğunluğu esas alınmıştır. Karma problemde $(Z, Z^m) = (y, \Delta)$ ve $l_0(\theta; T)$ Denklem (2.72)'de verilmiştir.

Karma örneğinde $E(l_0(\theta'; T) | Z, \hat{\theta}^{(j)})$ kolay bir biçimde Denklem (2.72)'de Δ_i ile yükümlülükler $\hat{y}_i(\hat{\theta})$ tarafından değiştirilir ve adım 3'de en büyükleme sadece ağırlıklandırılmış ortalamalar ve varyanslardadır.

EM algortimasının neden genel çalıştığının bir açıklaması verilirse:

$$\Pr(Z^m | Z, \theta') = \frac{\Pr(Z^m, Z | \theta')}{\Pr(Z | \theta')} \quad (2.80)$$

olduğu için,

$$\Pr(Z | \theta') = \frac{\Pr(T | \theta')}{\Pr(Z^m | Z, \theta')} \quad (2.81)$$

yazılabilir.

Log-olabilirlik açısından, l_1 'in koşullu yoğunluğu $\Pr(Z^m | Z, \theta')$ esas aldığı, $l(\theta'; Z) = l_0(\theta'; T) - l_1(\theta'; Z^m | Z)$ 'e sahiptir. Parametre θ tarafından yönetilen $T|Z$ dağılımına kıyas ile koşullu beklentileri alarak, Denklem (2.82)'yi verir:

$$l(\theta'; Z) = E[l_0(\theta'; T) | Z, \theta] - E[l_1(\theta'; Z^m | Z) | Z, \theta] \quad (2.82)$$

(Hestie ve ark. 2008).

Algoritma 2.2. EM Algoritması

1. Parametreler $\hat{\theta}^{(0)}$ için ilk tahminlerle başlama
2. Beklenti Adımı (Expectation Step): j inci adımda

$$Q(\theta^r, \hat{\theta}^{(j)}) = E(l_0(\theta'; T) | Z, \hat{\theta}^{(j)}) \quad (2.83)$$

kukla argüman θ' 'nın bir fonksiyonu gibi hesapla.

3. En Büyükleme Adımı (Maximization Step):

θ' üzerinde $Q(\theta', \hat{\theta}^{(j)})$ 'nin en büyüleyicisi gibi yeni tahmin $\hat{\theta}^{(j+1)}$ belirlemek.

4. Adım 2 ve 3 yakınsama olasıya kadar yinelenir.

$$\equiv Q(\theta', \theta) - R(\theta', \theta) \quad (2.84)$$

M adımında EM algoritması asıl amaç fonksiyonu $l(\theta'; Z)$ 'den ziyade θ' üzerinde $Q(\theta', \theta)$ 'yi en büyükler. Neden $l(\theta'; Z)$ en büyüklemede başarılıdır sorusu cevaplanırsa: $R(\theta^*, \theta)$, θ tarafınan endekslenen aynı yoğunluğa göre, bir yoğunluğun (θ^* tarafından endekslenmiştir) bir log-olabilirlik beklentisi olduğu böylece (Jensen'nin eşitsizliği tarafından) $\theta^* = \theta$ olduğunda, θ^* 'nın bir fonksiyonu gibi en büyüklendiği dikkate alınmalıdır. Böylece eğer θ' , $Q(\theta', \theta)$ 'yı en büyüklerse Denklem (2.85) görülür:

$$l(\theta'; Z) - l(\theta; Z) = [Q(\theta', \theta) - Q(\theta, \theta)] - [R(\theta', \theta) - R(\theta, \theta)] \geq 0 \quad (2.85)$$

Böylece EM yinelemesi log-olabilirlikte asla azalmaz. Bu argüman da M adımında tam en büyüklemenin gerekli olmadığını açıkça ortaya koymaktadır: Sadece $\hat{\theta}^{(j+1)}$ değerinin bulunması gerekmektedir; böylece ilk argümanın bir fonksiyonu gibi $Q(\theta', \hat{\theta}^{(j)})$ artar. Bu $Q(\hat{\theta}^{(j+1)}, \hat{\theta}^{(j)}) > Q(\hat{\theta}^{(j)}, \hat{\theta}^{(j)})$ dir. Bu gibi yordamlar GEM (generalized EM) ya da (genelleştirilmiş EM) algoritmaları olarak adlandırılırlar. EM algoritması aynı zamanda bir minörizasyon yöntemi olarakta görülebilir (Hestie ve ark. 2008).

2.3.3. Bir Maksimizasyon-Maksimizasyon Yöntemi Olarak EM

Bu başlıkta EM yönteminin farklı bir görüşü, birleşik maksimizasyon algoritması olarak gösterilecektir. Denklem (2.86) göz önüne alındığında:

$$F(\theta', \tilde{P}) = E_{\tilde{P}}[l_0(\theta'; T)] - E_{\tilde{P}}[\log \tilde{P}(Z^m)] \quad (2.86)$$

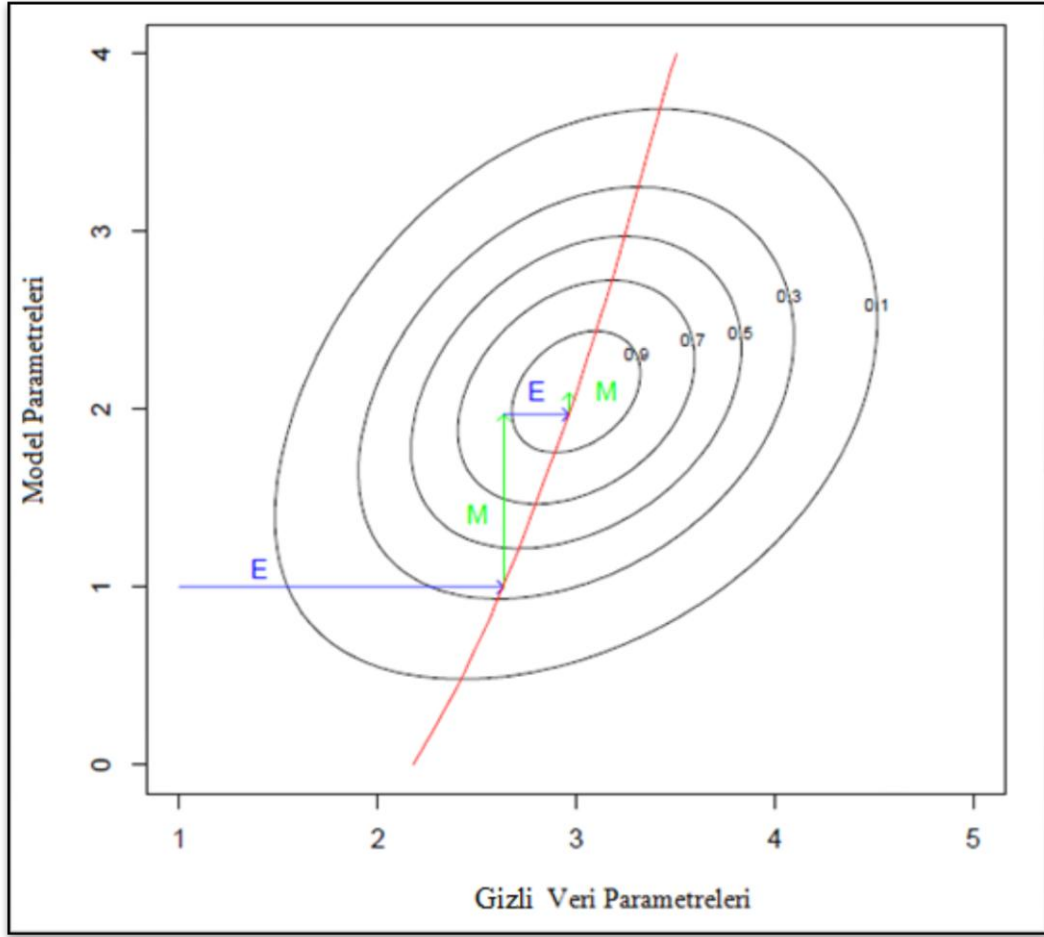
Burada $\tilde{P}(Z^m)$, gizli veriler Z^m üzerinde, herhangi bir dağılımdır. Karma örneğinde, $\tilde{P}(Z^m)$, $\gamma_i = \Pr(\Delta_i = 1 | \theta, Z)$ olasılıklarının kümesinden oluşmaktadır. Hatırlatmak gerekirse $F, \tilde{P}(Z^m) = \Pr(Z^m | Z, \theta')$ de Denklem (2.84)'den gözlemlenmiş verilerin log-olabilirliğidir. Fonksiyon F kendi maksimizasyonu kolaylaştırmak için log-olabilirliğin etkisini genişletir.

EM algoritması bir argüman sabitleme ve diğerleri üzerinden maksimizasyon yaparak, θ' ve $\tilde{P}(Z^m)$ üzerinden F için birleşik maksimizasyon ya da birleşik en büyükleme metodu olarakta görülebilir. Sabitlenmiş θ' için $\tilde{P}(Z^m)$ üzerinde maksimize etmek, Denklem (2.88)'deki gibi gösterilebilir:

$$\tilde{P}(Z^m) = \Pr(Z^m | Z, \theta') \quad (2.88)$$

Bu dağılım, E-adımı tarafından hesaplanmıştır. Örneğin Denklem (2.74)'deki karma örneği. M-adımında, sabitlenmiş P ile θ' üzerinde, $F(\theta', \tilde{P})$ maksimize edilir: Bu ikinci terim θ' içermeyeceği için, ilk terim $E_{\tilde{P}}[l_0(\theta'; T) | Z, \theta]$ 'in aynı şekilde maksimizasyon edilmesidir.

Sonuç olarak, $F(\theta', \tilde{P})$ ve gözlemlenmiş veri log-olabilirlik, $\tilde{P}(Z^m) = \Pr(Z^m | Z, \theta')$ olduğunda uyumlu olduklarından, eski maksimizasyonu daha sonraki gelen maksimizasyonu gerçekleştirir. Şekil (2.33) bu sürecin şematik görünümünü göstermektedir. EM algoritmasının bu görünüşü alternatif maksimizasyon süreçlerine neden olur. Örneğin tek bir seferde tüm gizli veri parametrelerini tümüne göre maksimize etmeye gerek yoktur, bunun yerine M-adımı ile değişen, bir seferde birisi üzerinden maksimizasyon yapılabilir (Hestie ve ark. 2008).



Şekil 2.33. EM algoritmasının maksimizasyon-maksimizasyon görünümü. Gözlemlenmiş veriler log-olabilirlik $F(\theta', \tilde{P})$ 'nın yükselti eğrileri (miktarı çoğaltılmış) (augmented) gösterilmiştir. E adımı, latent veri dağılımının parametreleri üzerinde log-olabilirliği maksimuma çıkarmaya eşdeğerdir. M adımı log-olabilirliğin parametreleri üzerinde maksimizasyon yapar. Kırmızı eğri gözlemlenmiş veri olabilirliğe karşılık gelmektedir. Profil θ' 'nın her bir değeri için $F(\theta', \tilde{P})$ maksimize edilerek elde edilmiştir. (Hestie ve ark. 2008)

3. LİTERATÜR ÖZETİ

Mayank Tyagi ve arkadaşları grafik kesme başlama ve EM algoritması esas alınarak bir bağlam; duyarlı sınıflandırma tekniği başlıklı 2008 yılında kaleme aldıkları makalelerinde kendi geliştirdikleri aşamalı olarak kullandıkları algoritmaları ile bulanık *c*-algoritmalar algoritmasını kullanmışlar ve kullandıkları bu algoritmanın parametre tahminlerini EM Algoritması ile tahmin etmişlerdir (Tyagi ve ark. 2008).

Fernando Perez Nava ve arkadaşları uzaktan algılama görüntülerinde grafik kesme değişim tespiti isimli 2002 yılına ait makalelerinde uzaktan algılanmış görüntülerdeki değişimi gizli Markov Serisi (HMRF) yardımı ile incelemiştir. Bu değişim incelemesinde optimum sınıflandırıcı için sonsal dağılımda Maximum Posteriori (MAP) dağılımını varsayımı altında yapmışlardır. Fakat MAP sonsal dağılımı baz alınarak HMRF yardımı ile yapılan değişim analizinde katsayı karışıklığı olduğu için tahminleme tekniklerine ihtiyaç duymuşlardır. Bu yüzden çalışmalarında yukarıdaki sayılan sorunları yok etmek için grafik kesme tekniği ve parametre tahmini için ise EM algoritması kullanmışlardır (Nava ve ark. 2002).

L.Gomez-Chova ve arkadaşları hiperspektral uzaktan algılama görüntüleri için yarı ön bilgilendirmeli sınıflama metodu isimli 2003 yılında yayınlamış oldukları makalelerinde yeni hiperspektral görüntü sınıflandırıcısı geliştirmeye çalışmışlardır. Bunu yapmadan önce klasik öğrenmeli ve öğrenmesiz görüntü sınıflandırma tekniklerinin dez avantajları hakkında bilgiler vermişlerdir; öğrenmeli sınıflandırmanın eş zamanlı ve eş koşullar altında örneklem görüntünün tüm görüntüyü sınıflandırmak için işe yarayacağını aksi taktirde sıklıkla örneklem görüntünün işe yaramayacağını, Öğrenmesiz görüntü sınıflandırmasında ise örneklem öğrenmesiz görüntünün tüm görüntü için etiket oluşturmaya duyarlı olmadığını vurgusunu yapmaktadır. Daha sonra klasik öğrenmeli ve öğrenmesiz görüntü sınıflandırmasının engel ve otomatikleştirmesinden kaçınmak için EM algoritmasının formülleri temel alan yeni bir yaklaşım önermişlerdir ve bu tekniği çok spektral bant kombinasyonuna uygulayıp; Isodata, Learning Vector Quantization, Gaussian Maximum Likelihood, Expectation-Maximization ve Nerual Networks teknikleriyle karşılaştırmışlar ve kendi yaklaşımlarının kesinlik

ve sađlamlılık aısından istedikleri hedefleri sađladığını anladıklarını raporlamışlardır (Gomez ve ark. 2003).

Thales Sehn Korting ve arkadaşları uzaktan algılama verileri sınıflandırması için EM algoritmasının bir modifiye versiyonunun deęerlendirmesi isimli makalelerinde uzaktan algılanmış uydu görüntüleri için EM algoritması yardımı ile yapılan sınıflandırma tekniğinde iki önemli sorun olan varyans-kovaryans matrisi ve ilksel tahminler için kullanılan klasik K-Ortalamalar tekniğine yeni bir modifiye teknik geliştirerek varyans-kovaryans matrisindeki uydu görüntüsündeki sınıfları temsil eden merkezlerin birbirine çok yakın olması sorununu ve ilksel tahminlerin daha doęru yapılması sorununu çalışmıştır (Korting ve ark. 2004).

Refaat M. Mohamed ve arkadaşı multispektral verilerin sınıflandırma için yeni bir ön bilgilendirmesiz yaklaşım isimli yapmış oldukları arařtırmada ön bilgilendirmesiz piksel-deneyimli tekniğini uygulamışlardır. Senaryo olarak karma daęılım modelinin rastgele alan seçimi formatında çalışılmıştır. Parametre tahmini için EM algoritması teknięi kullanılmıştır. Yapılan iterasyonlar sınıf sayısını belirlemektedirler. Parametreler ise her bir sınıfa ait parametrelerdir. Teoride hem parametrik hemde parametrik olmayan olarak uygulanan EM algoritması teknięi bu çalışmada sadece parametrik durum için yapay ve gerçek çoklu spektral uydu görüntüsüne uygulanarak dięer klasik sınıflandırma teknikleri ile karşılaştırılmıştır (Mohamed ve Farog 2003).

Sankar K. Pal 2002 yılında kaba küme başlangı EM algoritması kullanarak çoklu spektral biçimlendirme isimli yapmış olduęu çalışmada Çoklu spektral görüntü bölümlendirmesi için EM teknięi kullanılmıştır. Bu teknięi kullanmasındaki amacın bölümlendirme işleminde kesin olmayanı tahmin ederek ortadan kaldırmak olduęunu belirtmiştir. EM algoritması teknięini uygularken hızlı yakınsama ve yerel minimum problemini ortadan kaldırarak EM algoritmasının performansını arttırmak için Pawlak'ın ön yaklaşımli kümeler teorisini kullanılmıştır (Pal ve Mitra 2002).

Paolo Matero ve arkadaşları 2005 yılında kaleme aldıkları olasılık yoğunluk tahmini esas alınarak, destek vektör makineleri (SVM) vasıtasıyla uzaktan algılama görüntülerinin kısmi ön bilgilendirmeli sınıflandırması arařtırmalarında öğrenmeli sınıflandırmanın dezavantajından bahsetmişlerdir; öğrenilmiş sınıflandırma varsayılan ilksel olasılık yoğunluk daęılımının üzerinde çalışılan

tüm görüntü için aynı olduğu düşünülürken aslında gerçekte uydu görüntüsünün ait olduğu yer gerçeğinin arazi topolojisinin olasılık yoğunluk fonksiyonunun farz edilen ilksel olasılık yoğunluk fonksiyonundan farklı olmasının kuvvetle muhtemel olduğunu tespit etmişlerdir. Yaklaşımlarında ise Support Vector Machine (SVMs)'i kullanarak bilinmeyen sınıflardan bilinen sınıfa doğru Bayes teoremi yardımı ile ilksel olasılık yoğunluk fonksiyonunu tahmin etmeye çalışmışlardır (Mantero ve ark. 2005).

Joseph W. Richards ve arkadaşları uzaktan algılama görüntüleri analizi için ağırlıklandırılmış model sınıflandırma tabanlı isimli yapmış oldukları araştırmada bölümlendirilmiş görüntülerin birimlerine ağırlıklı sınıflandırma tekniğini uygulamışlardır. Bunun için ilk önce uzaktan algılama uzmanlarının analiz ettikleri uzaktan algılama görüntülerinin haritasını oluşturmuşlardır. Kendi geliştirdikleri ağırlıklandırılmalı sınıflandırma metodunda pikseller ilgili sınıfları ile ilgili olarak ağırlıklandırılmışlardır. Bu ağırlıklandırmayı piksel piksel nitelendirirken EM algoritması kullanarak ortalama ve standart sapmaların tahminlerini elde etmişlerdir. Geliştirdikleri tekniğin klasik standart tekniklere göre daha kesin sonuçlar verdiğini belirtmişlerdir. Daha sonra bu tekniği Venüs gezegeni görüntüsüne uygulamışlardır (Richards ve ark. 2010).

Yang Hong Lei ve arkadaşları 2013 yılında yapmış oldukları uzaktan algılama sınıflandırması için bir EM algoritması geliştirilmesi isimli araştırmada EM algoritmasının iki önemli sorununu ortaya koymuşlardır. İlk sorun varyans-kovaryans matrisinin gerçekten farklı olabilmesi iken ikinci sorun ise rastgele seçilen ilk değerlerin hassaslığı problemi olduğunu belirtmişlerdir. Yaptıkları çalışmada ilk olarak ilk öğrenme değerlerinin k-ortalamlar tekniği temel alınarak temel bileşenler analizinden elde edilen olasılık yoğunluk fonksiyonu ilksel değerler için oluşturulmuştur. Bu yaklaşım tahmin edilen ilksel değerlerin merkezlerinin rastgelelikten kaçınmasını sağlamıştır. İkinci modifikasyonlarında ise görüntü üzerindeki korelasyonsuz verilerinin temel bileşenler analizi ile dönüştürülmesini yapmışlardır. Bu yolla EM algoritmasını belirleyen bileşen katkı payıdır (Lei ve ark. 2013).

Iftekhar Naim ve arkadaşı 2012 yılında dengesiz karma katsayılar ile Gauss karma model için EM algoritmasının yakınsaması isimli yapmış oldukları çalışmada EM algoritmasının yakınsama hızının karma dağılımdaki sınıf sayısına

bağlı olduğunu belirtmişlerdir. Araştırmalarında ise karma katsayıların EM algoritmasının yakınsaması üzerindeki etkisini araştırmışlardır. Karma dağılım üzerindeki sınıflar üst üste binince EM algoritmasının yakınsaması karma katsayıların artması arasındaki dinamik bölge gibi azalmış olduğunu gözlemlemişlerdir. Geliştirdikleri algoritmaya karşı-sertleştirme algoritması adını vermişlerdir. Bu algoritma karma dağılımdaki her bir dengesiz sınıf için EM algoritmasının yakınsama hızını önemli bir derecede geliştirmiştir. Standart optimizasyon teknikleri; BFGS, Conjugate Gradient ve geleneksel EM algoritması ile kendi algoritmalarını karşılaştıran ikili daha sonra Bayes yaklaşımı için avantajlarını ortaya koymuşlardır (Naim ve Gildea 2012).

Louis Alberto Garcia ve arkadaşları 2001 yılında yapmış oldukları olabilirlik neticeleri için Monte Carlo EM algoritmalarının alternatif uygulamaları isimli çalışmada varyans bileşenlerinin Monte Carlo tahminleyicisi için kısıtlı en çok olabilirlik kullanılmış daha sonra EM algoritması yardımı gözden geçirilmiştir. Üçüncü metot olarak similasyon verisi üzerinde bu tekniklerin karşılaştırmalı performans ölçümleri yapılması önerilmiştir (Cortes ve Sorensen 2001).

Bo Thiesson ve arkadaşları 2001 yılında yapmış oldukları geniş veri tabanları için EM ivmelenmesi isimli çalışmada geniş veri tabanları için EM algoritmasının ivmelenmesini incelemişlerdir. EM algoritmasının parametre ve eksik veri tahmini için güzel bir teknik olduğunu bahsetmişlerdir. Fakat geniş veri tabanlarında EM algoritmasının geniş veri setlerinde bazı problemler çıkardığını belirtmişlerdir. Bu problemleri gidermek için iki yaklaşımda bulunmuşlardır. EM algoritması iterasyona devam ettikçe yakınsamalar belirli bloklar oluşturmaktadır. İlerleyen süreçte bloklar EM algoritmasına dramatik bir şekilde etki etmektedir. Buna karşın araştırmacıların yaptıkları yaklaşım en yakın ve en uygun bloğu seçmektir. İkinci yaklaşıma tembel EM algoritması ismini veren araştırmacılar, iterasyonlar esnasında veri durumları arasında en önemli olanını seçme yaklaşımında bulunmuşlardır (Thiesson ve ark. 2001).

Sergey Kirshner ve arkadaşları EM algoritması kullanarak galaksi şekillerinin sınıflamasını öğrenmek isimli yapmış oldukları astronomi araştırmasında, galaksilerin şekillerini EM algoritmasına öğreterek galaksileri sınıflandırmışlardır. Galaksileri morfolojik ve piksel yoğunluk karakteristiklerine

göre inceleyerek olasılıksal model bazında öğreten yazarlar galaksileri otomatik olarak kimliklendirecek bir yaklaşım üzerinde durmuşlardır. EM algoritmasını ise galaksilerin uzayda hangi yörünge üzerinde durduğunu ve nasıl hızlandıklarını öğrenmek amacı ile kullanmışlardır (Kirshner ve ark. 2003).

Shu-Ching Chang ve arkadaşı 2007 yılında EM algoritması isimli kaleme aldıkları makalede EM algoritması hakkında genel bilgiler vermişler ve teorik yapısı hakkında açıklamalarda bulunmuşlardır. Veri analizi yapmadan önce veri analizini anlamanın ne kadar önemli olduğunu vurgulayan ikili gerçek hayat verilerinde çoğu kez verilerin yer değiştirmesinden dolayı eksik veri durumunun ortaya çıkabileceğini ve bu eksikliği EM algoritmasının eksik veri ya da veriler için parametre tahmini yapacağını önemle belirtmişlerdir (Chang ve Kim 2007).

Laurent Bordes ve arkadaşları 2006 yılında bir yarı parametrik karma model için bir EM algoritması isimli yapmış oldukları araştırmada yarı parametrik karma dağılım için EM algoritmasını kullanmışlardır. Bir çok modelin parametrelerinin tanımlanması genellikle açık değildir. Tanımlanması gerektiğinde de karma dağılımın varsayımı altında gerçekleşir. Bu çalışmada yazarlar EM algoritmasını kullanarak, yarı parametrik karma modeller için geniş bir alana uygulanabilirliğini ortaya koymuşlardır. Bu durumu sağlamak için birkaç Monte Carlo simülasyonu üzerinde çalışılmıştır (Bordes ve ark. 2006).

Dechavudh Nityasuddhi ve arkadaşı 2003 yılında belirli varyans bileşenleri ile normal modeller için EM algoritmasının tahmininin asimtotik özellikleri isimli yapmış oldukları araştırmada, normal karma modeller ile dağılımın belirli varyans bileşenleri için EM algoritmasının asimtotik özelliklerini incelemişlerdir. İstatistikte önemli bir yere sahip olan yansızlık ve yanlılık ve de belirli bir veri setinin ortalamalarının karesini alınarak yapılan çeşitli tahmin hesaplamalarını yukarıdaki teknik kullanarak bulunmaya çalışılmıştır. Böylece iyi bir tahmin edici kavramına yeni bir yaklaşım getirilmesi amaçlanmıştır (Nityasuddhi ve Böhning 2003).

Robert D. Nowak yapmış olduğu algılayıcı ağlarda yoğunluk tahmini ve kümeleme için EM algoritma dağılımı isimli araştırmada algılayıcı ağlarında yoğunluk tahmini ve kümeleme için EM algoritmasını incelemiştir. Bir çok elektronik alıcı için Gauss karma dağılım modeli oluşturulmuş ve EM algoritması

yardımı ile elektronik alıcı ağı için parametre tahmininde bulunulmuştur (Nowak 2003).

Nikos Vlassis ve arkadaşı 2002 yılında Gauss karma öğrenme için bir açgözlü EM algoritması isimli yapmış oldukları araştırmada Gauss karma öğrenme için açgözlü EM algoritması adını verdikleri araştırmalarında gerçek karma bileşen sayısının tam olarak bilinmemesi ve de olabilirlik fonksiyonun birçok yerel maximumunun tarafından EM algoritmasını takılı bırakabileceği problemleri karşısında bileşen sayısını tek değerden başlatıp en fazla k ya kadar arttırmışlardır. Daha sonra olabilirlik deneme veri seti açısından bu yaklaşımın daha üstün olduğunu belirtmişlerdir (Vlassis ve Likas 2002).

Franz Pernkopf bir hibrit genetik EM algoritması isimli yapmış olduğu çalışmada Gauss karma modellerin başlangıç değerleri için hibrit genetik algoritma yakalaşımını önermiştir. Gauss karma modelin ilk değerlerinin tahminini EM algoritmasını ve genetik algoritma karma modeli ile birleştiren araştırmacı modelin ilk tahmin değerlerine olan duyarlılığını azaltarak öğrenilmiş Gauss karma dağılım üzerinde bileşen sayısını karşılaştırmalı olarak incelemiştir (Pernkopf 2005).

Sam Roweis temel bileşenler analizi (PCA) ve duyarlı temel bileşenler analizi (SPCA) için EM algoritmaları isimli yapmış olduğu çalışmada temel bileşenler analizi ve duyarlı temel bileşenler analizi için EM algoritmasını incelemiştir. EM algoritması birkaç özvektör ve birkaç özdeğer için çok geniş çapta ve büyüklükte veriye dönüştürülmesine olanak sağlamakta olduğunu belirlemiştir (Roweis 1998).

Cedric Archambeau ve arkadaşları sonlu Gauss karma modeller için EM algoritmasının yakınsama problemleri isimli 2003 yılında kaleme aldıkları araştırmalarında EM algoritmasının sonlu Gauss karma modeller için yakınsama problemini ele almıştır. Karma Gauss dağılım modelin parametre tahmini için EM algoritmasını kullanmak zarif bir yol olsa da sayısal zorluklardan dolayı yakınsamanın yanlış olabileceği belirtilmiştir. Bu duruma sebep olarak tekrarlanan örneklem veri kümelerinin etrafında aynı sonuçların oluşmasıdır. Bu durumu incelemek için olayın teorik yapısının başlangıcına değinen ikili, modeli izole ederek durumu açıklamaya çalışmış ve de durumun kökenine inmek için

başlangıçta bileşen sayısı 0 olursa karma modelin tekrarlamaya karşı izole olacağı fikrinden hareketle yola çıkmışlardır (Archambeau ve ark. 2003).

Franz Pernkopf ve arkadaşı 2005 yılında Gauss karma öğrenme modeli için genetik esaslı EM algoritması isimli yapmış oldukları çalışmada Gauss karma öğrenme modeli için genetik bazlı EM algoritmasını incelemişlerdir. Genetik algoritma ve EM algoritmasını birlikte kullanan ikili EM algoritmasından daha iyi sonuç elde ettiklerini ve kurdukları kombine algoritmanın ilksel değerlerin hassasiyetinden daha az etkilendiğini sonuç olarak yazmışlardır (Pernkopf ve Bouchaffra 2005).

Jeff A. Bilmes 1998 yılında Gauss karma ve gizli Markov modellerinin uygulama parametrelerinin tahmini için hassas öğrenilmiş EM algoritması isimli yapmış olduğu çalışmasında Gauss karma dağılım ve gizli Markov Modellerinin uygulama parametrelerinin tahmini için hassas öğretilmiş EM algoritmasını araştırmıştır. İlk amaç olarak Karma Gauss yoğunluk modelinin parametrelerini bulmuş daha sonra ise gizli Markov modelinin parametrelerini EM algoritması yardımı ile bulmuştur. Yukarıda sayılan iki amaç için yapılan parametre tahminleri kesikli ve Gauss karma modelleri için yapılmıştır (Bilmes 1998).

Alan L. Yuille ve arkadaşları 1994 yılında istatistiksel fizik, karma dağılımlar ve EM algoritması isimli yapmış oldukları İstatistiksel fizik, dağılımların karması ve EM algoritması ismini verdikleri araştırmalarında optimizasyon yaklaşımı ve istatistiksel fizik ya da karma model tabanlı öğrenme arasında güçlü bir ilişki tespit etmişlerdir (Yuille ve ark. 1994).

Ravindra Kollu ve arkadaşları 2010 yılında karma olasılık dağılımı fonksiyonlarına rüzgar hızlı dağılım modeli isimli yapmış oldukları araştırmada rüzgar hızlarının dağılımı için karma olasılık dağılımı fonksiyonlarını araştırmışlardır. Rüzgar hızı değerlendirmelerinde seçilen olasılık yoğunluk fonksiyon seçebilme kabiliyeti rüzgar hızı frekans dağılımının tanımlanması üzerinde çok önemli olduğunu vurgulayan araştırmacılar, üç tip karma dağılım modeli önermişlerdir (Kollu ve ark. 2010).

G.J. McLachan ve arkadaşı karma modellerde EM algoritması için hesaplama sorunları isimli yapmış oldukları araştırmada karma dağılım modellerindeki EM algoritmasının hesaplama sorunlarını ele almışlardır. EMMIX modeli adını verdikleri ve geliştirdikleri yaklaşım ile karma dağılımlara uyumu

kolaylaştırmışlardır. Eğer kullanıcı tarafından ilksel değerler uygun olarak girilemese bile geliştirdikleri EMMIX modeli için bu sorun olmamaktadır. EMMIX modeli birkaç seçenek bulundurmaktadır. Bunlardan birisi olan test edilen bileşen sayısından tekrar örneklem seçmeyi yürütmeyi hükmetmek buna dahildir (McLachlan ve Peel 1999).

Zhihua Zhang ve arkadaşları 2003 yılında yarma ve kaynaştırma işlemleri ile Gauss karma modeller için EM algoritması isimli yapmış oldukları araştırmada EM algoritması için Gauss karma model ile yarma ve kaynaştırma modelini araştırmıştır. Yapılan araştırmada bu yolla EM algoritmasının sorunlarından birisi olan lokal yakınsama sorunu Gauss karma modele yarma ve kaynaştırma modeli ile uygulanmış ve bu şekilde lokal yakınsama sorunu hafifletilmiştir (Zhang ve ark. 2003).

Pekka Paalanen 2004 yılında Gauss karma model ve EM tahmini kullanarak Bayes sınıflandırması isimli yapmış olduğu araştırmada Gaussian karma model ve EM tahmini kullanarak Bayes sınıflandırması; uygulamaları ve karşılaştırmaları ismini veridiği araştırmasında Bayes sınıflandırmasının bulunduğu matlab paket programını Gauss karma dağılım yoğunluk fonksiyonu yardımı ile geliştirilmeyi amaçlanmıştır (Paalanen 2004).

Haifeng Li ve arkadaşları düzenlenmiş EM algoritması isimli yapmış oldukları araştırmada EM algoritmasının düzenlenmesini araştırmışlardır. EM algoritması gözlem değerlerinin tamamlanmamış değerleri için güçlü bir etkiye sahipken eksik veriler için herhangi bir kontrolünün yok olduğunu araştırmalarının başında belirten araştırmacılar bu sorunu ortadan kaldırmak için EM algoritmasını cezalandırılmış olabilirlik fonksiyonu kullanarak düzenleme getirmişlerdir (Li ve ark 2005).

Mingjun Zhong ve arkadaşlarının 2004 yılında Gauss gürültüsünün bağımsız bileşen analizi için bir EM algoritması isimli yapmış oldukları araştırmada Gauss gürültüsünü bağımsız bileşen analizi için EM algoritması ile incelemiştir. Şartsal momentlerin tahmininin sonsal kaynağının tahmini en çok sonsal tarafından gerçekleştirilebileceğini belirterek araştırmalarına başlayan yazarlar, yaklaşık şartsal momentlerin EM algoritmasının geliştirilmesi için uygun olup bu durumun bir çok muhtemel kaynakların yorumlanması için ve gürültü bağımsız bileşen analizinde öğrenme parametreleri için elverişli olduğunu bulmuşlardır.

Teorideki bu durum için daha sonra simülasyon ortamında deneme yaparak sağlamada bulunmuşlardır (Zhong ve ark. 2004).

Arnaud Doucet ve arkadaşları 2002 yılında Markov Zinciri Monte Carlo (MCMC) kullanarak marjinal maksimum bir sonsal tahmin isimli yapmış oldukları araştırmalarında Markov Zinciri Monte Carlo Kullanarak marjinal maksimum sonsal dağılımın tahmini yapmışlardır. MCMC (Markov Chain Monte Carlo) tekniği Bayes neticesi için birçok karmaşık problemi kolaylaştırmaktadır. Fakat bu yaklaşım veri seti geniş olduğunda marjinal en fazla sonsal dağılıma uygun hale getirilmiş olamamaktadır. İşte bu çalışmada araştırmacılar State-Augmentation for Marginal Estimation (SAME) ismini verdikleri teknikle bu problemi ortadan kaldırmayı hedeflemişlerdir (Doucet ve ark. 2002).

Richard A. Levine ve arkadaşı 2001 yılında Monte Carlo EM algoritmasının uygulamaları isimli yapmış oldukları araştırmada Monte Carlo EM algoritmasının uygulamalarını incelemişlerdir. EM algoritmasının E-Adımı Monte Carlo modeli ile modifiye edildiğinde MCEM modeli oluştuğunu belirten araştırmacılar, kendileri için ayrıca MCEM modeli oluşturup bunu iki veri seti ile genel karma doğrusal model ile analiz etmişlerdir. Maliyet ve etkinlik açısından kendi MCEM modellerini farklı olduğunu belirtmişlerdir (Levine ve Casella 2001).

O.Eches ve arkadaşları karma olmayan hiperspektral görüntülere normal düzensel model ve MCMC metotlarının uygulanması isimli kaleme aldıkları makalelerinde karma olmayan hiperspektral görüntüleri normal düzensel model ve MCMC methodları ile kullanılmasını araştırmışlardır. Yaptıkları araştırmayı yeni bir karma olmayan algortimayla hiperspektral görüntü için kullandıkları belirten araştırmacılar; görüntünün her bir pikselinin sonuncu pikselin doğrusal bir kombinasyonu varsayımını modellemişler böylece her bir piksel kesin olmayan durumlar için yani sınıflandırma sonucunda pikselin hangi kümeye ait olduğunun bilinmediği durumlar için ilgili piksel rastgele olduğunu makalelerinde belirtmişlerdir (Eches ve ark. 2009).

4. MATERYAL YÖNTEM

İlk olarak bu bölümde daha önceki literatür taramalarından yararlanılarak, bu tezde yapılmış yerli ve yabancı benzer ya da yakın nitelikteki çalışmalar araştırılıp incelenmiş ve bu tezin konusundaki araştırmaya yakın nitelikte olanlar değerlendirilmiştir.

Literatür taraması için Anadolu Üniversitesi kütüphane çevrimiçi katalog tarama sayfasından (<http://www.kdm.anadolu.edu.tr/>) yararlanılarak kitap, elektronik kitap (e-kitap), makale, ve projeler gibi yayınlar incelenmiştir.

Ulusal tezler için Yükseköğretim Kurulu Başkanlığı ulusal tez arama sayfasından (<https://tez.yok.gov.tr/UlusalTezMerkezi/tarama.jsp>) yararlanılmıştır.

Bunun yanında daha farklı ve başka dokümanların araştırılması için internet arama motorlarından faydalanılmış, ayrıca (www.youtube.com) üzerinden yurt dışındaki bazı üniversitelerin dersleri incelenmiştir.

Uydu verileri için Landsat, uydu görüntü verileri (<http://earthexplorer.usgs.gov/>) sitesinden indirilmiştir. Ayrıca NASA'nın internet sitesi (<http://www.nasa.gov/>) adresinden görüntü verisi indirilmiştir.

Yapılan çalışma uzaktan algılama verisi tipindedir ve istatistiksel öğrenme tabanlı bir modifiye araştırma yapılmıştır. Uygulanan teknik, istatistiksel parametrelerin tahmini ile yapılan ön bilgilendirmeli istatistiksel öğrenme tekniğidir. Bu tekniğin uzaktan algılamadaki İngilizce karşılığı “supervised” dir. İstatistiksel öğrenme verileri ilgili spektral aralık kombinasyonlarındaki uzaktan algılama verilerinden seçilen tahminler ile oluşmaktadır. Önemli istatistiksel kavramların uzaktan algılamadaki karşılıklarının ne olduğu araştırma öncesinde tespit edilmiştir; (Çömlekçi, 2005, sözlü görüşme)’ye göre görüntünün en küçük parçasına piksel denir. Bu tanımla piksel istatistikteki “gözlem değeri” kavramıyla eşdeğerdir. Görüntü üzerindeki pikselin karşılık olduğu yer geçegi alanı ise istatistiksel birimdir. Her bir bant rassal (rastgele) değışkendir (Çömlekçi, 2005, sözlü görüşme).

Uygulamalar sırasında kullanılan modifiyeli ve modifiyesiz teorik yapı ve bu yapının uygulanmasını sağlayan kod ve bu kodun çalıştırılması sonucunda elde edilen sınıflandırılmış modifiyeli ve modifiyesiz EM algoritması yardımı ile elde edilen sınıflandırma sonucu görüntüleri ve bazıklasik uzaktan algılama

sınıflandırma teknikleri ile karşılaştırmaları ilerleyen bölümlerde ayrıntılı bir biçimde açıklanmıştır.

4.1. Materyal

İstatistiksel öğrenme kavramı için çok sayıda çeşitli ulusal ve uluslararası kaynak taranarak, yazılı dökümanlar belirlenmiş ve istatistiksel öğrenme kavramının teorik ve uygulamalı yapısı çok sayıda yazılı materyal aracılığı ile açıklanmış ve kullanılmıştır.

Bu tezde geliştirilen istatistiksel öğrenme tabanlı modifiye uzaktan algılama sınıflandırıcısı için yapılan literatür taramasında aynı yaklaşımda bulunup bulunmadığı araştırılmış, bunun yanında diğer yaklaşımların incelenmesi yapılmıştır. İstatistiksel öğrenme tabanlı sınıflandırıcılarda doğru ve performansı yüksek bir sınıflandırmaya engel olabilecek çeşitli sorunların ne olduğu ve en çok hangi durumun ortak sorun olduğu literatür materyal sayesinde tespit edilmiştir.

Bu tezde kurulan modifiye sınıflandırma tekniğini bilgisayar koduna dönüştürmek için matlab programı kullanılmıştır. Uzaktan algılama verilerinin modifiye EM algoritması ile sınıflandırılmış hali ASCII formatında kayıt edilmiş ve bu kayıttan tekrar çağrılarak .tiff ve .jpeg formatında sınıflandırılmış görüntü elde edilmiştir.

Uzaktan algılanmış uydu verileri için ön bilgilendirmesiz olarak Isodata sınıflandırması ile ön bilgilendirmeli sınıflandırma tekniklerinden; en kısa uzaklık, Mahalanobis uzaklık Erdas paket programında yapılmıştır. Bilinen ve sıkça kullanılan Isodata, en kısa uzaklık, Mahalanobis uzaklık sınıflandırma teknikleri için gerçekleştirilmiş modifiyesiz ve modifiyeli EM algoritması yardımı ile elde edilen sınıflandırma analizi ile aynı özelliklere sahip olmasına dikkat edilmiştir. Tüm sınıflandırma analizlerinde aynı kategorideki veriler için tahmini sınıf sayıları ve ön bilgilendirme sınıf sayıları aynı sayıda ve gerçeğine uygun oluşturulmuştur. Ayrıca ön bilgilendirmeli sınıflandırma analizlerinde ön bilgilendirme örneklerinin seçimi dikkatle yapıp uzman görüşü alınmıştır.

Daha sonra üç bant için sırası ile iki sınıf ya da bileşen, üç sınıf, dört sınıf, beş sınıf, 15 sınıf ve 20 sınıf için; modifiyesiz ve modifiyeli EM algoritması sonucu elde edilen parametre tahminleri ve karma model yardımı ile gerçekleştirilmiş olan sınıflandırma analizi sonucu görüntüleri, Isodata ön

bilgilendirmesiz sınıflandırma analizi sonucu görüntüleri, ön bilgilendirmeli olarak en kısa uzaklık, ve Mahalanobis uzaklık sınıflandırma analizi sonucu görüntülerinin görsel karşılaştırmaları yapılmıştır. Bu karşılaştırmada esas olarak önemli nirengi sınıfları esas alınmış ve hangi tekniğin bu nirengi sınıflarını daha iyi sınıflandırdığı ya da sınıflandıramadığı tespit edilmiştir.

4.2. Yöntem

Bu tezde kullanılan yazılı materyaller yardımı ve istatistiksel öğrenme kavramının genel prensipleri ile istatistiksel öğrenme kavramının teorik mantığı anlatılmıştır. Daha sonra istatistiksel öğrenme teknikleri ile yapılan ve uydu görüntü verilerinin sınıflandırılmasında kullanılan güçlü sınıflandırıcıların teorik yapısı anlatılmıştır. Bu yapılar anlatılırken araştırılan modifiye EM algoritması tekniğine yakın olmalarına özen gösterilmiştir.

Teorik yapısı anlatılan güçlü sınıflandırıcıların sınıflandırmaları ne kadar güçlü yapabildikleri, sınıflandırmayı yaparken ne kadar güvenilirlikte sınıflandırma yapabildikleri, etkinlikleri avantajları ve dezavantajları karşılaştırmalı olarak anlatılmıştır.

Bu güçlü öğrenme tabanlı sınıflandırıcıların daha sonra uzaktan algılama kavramı açısından ne kadar öneme sahip olduklarının anlaşılması için üzerinde karşılaştırma yapmak için farklı tiplerde çok bantlı uzaktan algılama verileri seçilmiştir. Seçilmiş olan bu farklı uydu görüntü verilerinin birbirinden ayıran temel özellikleri üç bant için tahmini olarak iki sınıf, üç sınıf, dört sınıf, beş sınıf ve 15 sınıfa sahip olmaları ile güneş sistemimizde gezegenlere ait verilerde 20 sınıf yani bileşene sahip olmalarıdır.

Bu farklılıklar ile EM algoritmasının nasıl çalıştığı incelenmiş ve çalışmama durumunda, bu soruna yol açan nedeni yok edecek olan modifiye teknik ilave edilmiştir. Aynı uzaktan algılanmış uydu verileri bazı klasik sınıflandırıcı teknikleride uygulanmış ve her bir aşamada EM algoritması ya da modifiye EM algoritması ile karşılaştırılmaları yapılmıştır. Yapılan karşılaştırmalar giriş bölümündeki hipoteze uygun olarak, olasılık bazlı ve olasılık bazlı olmayan şeklinde yapılmıştır. Daha ayrıntılı olarak açıklama gerekirse: EM algoritmasının modifiyesiz ve modifiyeli biçimi 2. bölümde ayrıntılı olarak açıklandığı üzere

sınıflandırma analizini parametre tahminleri ile elde edilen olasılık dağılımları ile yapar. Bunun yanında Isodata, en kısa uzaklık ve Mahalanobis uzaklık sınıflandırma teknikleri ise olasılık dağılımları ile değil uzaklık ölçütünü temel alarak sınıflandırma yaparlar.

Arazi kontrolü yapılmamasının nedeni ise; EM algoritmasının modifiyeli ve modifiyesiz biçiminin yalnızca ulaşılabilen yer ve konumlar için değil ulaşılabilen konumlar için de bilgi edinilmek için yapıyor olmasıdır. Örneğin gidilmesi şu an için olası olmayan uzak gezegenler hakkında bilgi edinilmek istendiğinde arazi kontrolü yapılması şu an için imkansızdır. Bunun yanında benzer şekilde mikrobiyolojide ve mikroskop altında yapılan araştırmalarda kontrol yapılması çok zor ya da bazı durumlar imkansızdır. Bunun gibi örnekler çoğaltılabilir.

Yukarıda açıklanan gerekçelerden dolayı daha etkin ve daha güvenilir ve olasılığa dayalı olarak çalışan modifiyesiz ya da modifiyeli EM algoritması yardımı ile gerçekleştirilen sınıflandırma tekniği kullanılarak diğer bazı klasik uzaklık bazlı sınıflandırıcılar ile karşılaştırılmıştır.

4.2.1. EM Algoritmasının İki Bileşenli Gauss Dağılımı için Uygulanması

İlk uygulamada 14 adet varyansızsal veri için iki bileşenli Gauss karma modeli uygulanacaktır. Bu uygulamanın yapılaş nedeni az sayıda sayısal veri ile teorik modelin daha kolay anlaşılmasını sağlamaktır. Varsayımsal veriler 1, 1.3, 2, 2.1, 4, 4.7, 4.8, 5, 5.3, 5.5, 7, 8, 8.5, 9, 10 olsun bu 14 adet veriyi iki bileşenli Gauss karma modele uyarlamak, yani karma iki normal dağılımı bulmak için daha önce anlatılan Algoritma (2.1) uygulanacaktır. Daha sonra sonuçların mantıklı olup olunmadığı kontrol edilecektir. Algoritma (2.1) tekrar hatırlanacak olunursa:

Algoritma 2.1. İki Bileşenli Gauss Karma Model İçin EM Algoritması

1. $\hat{\mu}_1, \hat{\sigma}_1^2, \hat{\mu}_2, \hat{\sigma}_2^2, \hat{\pi}$ parametreleri için ilk tahminlerin yapılması

1. Beklenti Adımı (Expectation Step): Yükümlülüklerin Hesaplanması

$$\hat{\gamma}_i = \frac{\hat{\pi}\phi_{\hat{\theta}_2}(y_i)}{(1-\hat{\pi})\phi_{\hat{\theta}_1}(y_i)+\hat{\pi}\phi_{\hat{\theta}_2}(y_i)}, \quad i = 1, 2, \dots, N. \quad (2.74)$$

2. En Büyükleme Adımı (Maximization Step): Ağırlıklandırılmış ortalamaların ve varyansların hesaplanması

$$\hat{\mu}_1 = \frac{\sum_{i=1}^N (1-\hat{\gamma}_i)y_i}{\sum_{i=1}^N (1-\hat{\gamma}_i)}, \quad (2.75)$$

$$\hat{\sigma}_1^2 = \frac{\sum_{i=1}^N (1-\hat{\gamma}_i)(y_i-\hat{\mu}_1)^2}{\sum_{i=1}^N (1-\hat{\gamma}_i)}, \quad (2.76)$$

$$\hat{\mu}_2 = \frac{\sum_{i=1}^N \hat{\gamma}_i y_i}{\sum_{i=1}^N \hat{\gamma}_i}, \quad (2.77)$$

$$\hat{\sigma}_2^2 = \frac{\sum_{i=1}^N \hat{\gamma}_i (y_i-\hat{\mu}_2)^2}{\sum_{i=1}^N \hat{\gamma}_i}, \quad (2.78)$$

ve karma olasılığı :

$$\hat{\pi} = \frac{\sum_{i=1}^N \hat{\gamma}_i}{N} \quad (2.79)$$

3. Adım 2 ve 3 yakınsama olasıya kadar yinelenir.

Bu algoritmaya uygun olarak geliştirilen 14 adet varsayımsal veriye ait matlab kodu aşağıda verilmiştir:

```
% İKI BİLESENLI GAUSS KARMA MODEL ICIN EM ALGORTIMASI
% BU KOD EMRE MOLA TARAFINDAN YAZILMISTIR
% ANADOLU UNIVERSITESI FEN BILIMLERI ENSTITUSU
% UZAKTAN ALGILAMA VE COGRAFI BILGI SISTEMLERI
% DOKTORA TEZI ICIN GELISTIRILMISTIR
clear all, close all, clc
format long
D= [1 1.3 2 2.1 4 4.7 4.8 5 5.3 5.5 7 8 8.5 9 10];
% İLK PARAMETRE TAHMINLERİ
Pa =input('Tahmini ilk P Degerini Giriniz=');
M1a= input('Tahmini ilk M1 Degerini Giriniz=');
M2a= input('Tahmini ilk M2 Degerini Giriniz=');
G11a = input('Tahmini ilk 1. Varyans Degerini Giriniz=');
G22a = input('Tahmini ilk 2. Varyans Degerini Giriniz=');
G1a=sqrt(G11a);
G2a=sqrt(G22a);
TUa=zeros(size(D));
for j=1:100
    j
    if j > 1
```



```


hold off
gm1=gmdistribution(mu1,sigma1,P1a);
X=min(D):0.01:max(D);
mu2=M2Ea;
sigma2=G2Ea;
z=normpdf(X,mu2,sigma2);
hold on
subplot(2,2,3)
plot(X,z,'r','LineWidth',5);
xlabel('X')
ylabel('Olasilik Degeri (P)');
title('Karma Dagilimin 2. Bilesenine Olasilik Yogunluk Fonksiyonu
Gragfi ');
hold off
gm2=gmdistribution(mu2,sigma2,(1-P1a));
end
x1 = D';
gm = gmdistribution.fit(x1,2)
xx = linspace(min(D),max(D))';
subplot(2,2,4)
plot(xx,pdf(gm,xx))
xlabel('X')
ylabel('Olasilik Degeri (P)');
title('Karma Dagilimin Olasilik Yogunluk Fonksiyonu Gragfi');
for j=1:2
line(xx,gm.PComponents(j)*normpdf(xx,gm.mu(j),sqrt(gm.Sigma(j))),'color','r')
end
end

```

Yukarıdaki matlab kodu yardımıyla, varsayımsal olarak üretilen 14 adet hipotetik veri için iç içe geçmiş iki normal dağılımın parametreleri elde edilmiştir. Bu kazanım iki bileşenli Gauss karma model olarakta adlandırılır.

Matlab kodunun ilk kısmında verilmiş 14 adet hipotetik veriye ilişkin olarak birinci ve ikinci normal dağılımların parametrelerine ilişkin tahmin değerlerinin girilmesi istenmiştir. İki bileşenli karma normal dağılıma ilişkin girilen tahmini parametre değerleri sayesinde EM algortiması süreci başlatılmıştır.

EM algoritması süreci başladıktan sonra algoritma (2.1)'de aşamaları ve formülleri gösterilmiş olan E-Adımı ve M-Adımı sırası ile matlab kodunda gerçekleştirilir. İlk iterasyon tamamlandıktan sonra döngü yardımı ile aynı işlemler tekrar başa döndürülür. Her ne kadar varyans değeri gerçekte negatif değer almasada, EM algortimasının iterasyonu esnasında kovaryans değerleri negatif değer alabilmektedir. Bu neden ile iterasyonun tamamlanamadan yani yakınsama olmadan EM algoritmasının durması ihtimaline karşı matlab kodunda birinci ve ikinci bileşene ait varyanslar negatif değer alır ise sıfıra çok yakın bir



Şekil 4.2. Uzaktan algılanmış Dukono bölgesinden alınmış küçük iki bileşenli örneklem görüntüsü
(Anonim, 2014)

Şekil (4.2)'deki görüntü verisinin tek renk ya da tek bantı için EM algoritması ile yapılacak sınıflandırma analizinde yine Algoritma (2.1) uygulanır: Şekil (4.2)'deki deniz ve kara sınıflarını ayırt etmek için kullanılan EM algoritmasına ait matlab kodu aşağıda verilmiştir:

```
% İKİ BİLESENLI UZAKTAN ALGILAMA VERISI İCİN
% EM ALGORİTMASI YARDIMI İLE PARAMETRE TAHMİNİ VE
% KARMA OLASILIK YOGUNLUK FONKSİYONLARI BULUNMASI
% VE GORUNTU SINIFLANDIRMASI
% PASİFİK OKYANUSU VOLKANİK DUKONO BOLGESİ
% EM ALGORİTMASI YARDIMI İLE KARA VE DENİZ AYIRIMI
% SINIFLANDIRMASI
% BU KOD EMRE MOLA TARAFINDAN YAZILMISTIR
% ANADOLU UNIVERSİTESİ FEN BİLİMLERİ ENSTİTUSU
% UZAKTAN ALGILAMA VE COĞRAFI BİLGİ SİSTEMLERİ
% DOKTORA TEZİ İCİN GELİSTİRİLMİSTİR
clear all, close all, clc
format long
load('C:\Users\EMRE\matlab codes\TEZ UYDU VERİ\dukono-
2\dukono_emb1.txt')
z=load('C:\Users\EMRE\matlab codes\TEZ UYDU VERİ\dukono-
2\dukono_emb1.txt');
D=(reshape(z,3770,1));
% İLK PARAMETRE TAHMİNLERİ
Pa =input('Tahmini ilk P Degerini Giriniz=');
M1a= input('Tahmini ilk M1 Degerini Giriniz=');
```



```

sigma1=G1Ea;
z=normpdf(X,mu1,sigma1);
hold on
subplot(3,3,2)
plot(X,z,'b','LineWidth',5);
xlabel('X')
ylabel('1. Bilesene ait Dagilimin Olasilik ');
('Yogunluk Fonksiyonu Degeri ');
title('Karma Dagilimin 1. Bilesenine Ait Dagilim ');
hold off
gm1=gmdistribution(mu1,sigma1,(1-P1a));
X=min(D):0.01:max(D);
mu2=M2Ea;
sigma2=G2Ea;
z=normpdf(X,mu2,sigma2);
hold on
subplot(3,3,3)
plot(X,z,'r','LineWidth',5);
xlabel('X')
ylabel('1. Bilesene ait Dagilimin Olasilik ');
ylabel('Yogunluk Fonksiyonu Degeri ');
title('Karma Dagilimin 2. Bilesenine Ait Dagilim ');
hold off
gm2=gmdistribution(mu2,sigma2,(P1a));
end
x1 = D;
gm = gmdistribution.fit(x1,2)
yy = linspace(min(D),max(D))';
subplot(3,3,4)
plot(yy,pdf(gm,yy))
for j=1:2
line(yy,gm.PComponents(j)*normpdf(yy,gm.mu(j),sqrt(gm.Sigma(j))),'color','r','LineWidth',2)
end
for j=100
for p=1:length(D);
p;
P1(p)=(1-P1a)*normpdf(D(p),M1Ea,G1Ea);
P2(p)=P1a*normpdf(D(p),M2Ea,G2Ea);
if P1(p)>P2(p)
c= 1;
elseif P1(p)<P2(p)
c= 2;
else
c= 0;
end
disp(' VERI NO VERI P1 P2
SINIF ')
disp([
p D(p) P1(p) P2(p) c
])
end
end
for p=1:length(D);
for j=100
p;
P1(p)=(1-P1a)*normpdf(D(p),M1Ea,G1Ea);
P2(p)=(P1a)*normpdf(D(p),M2Ea,G2Ea);
if P1(p)>P2(p)
c= 1; s=45 ;

```

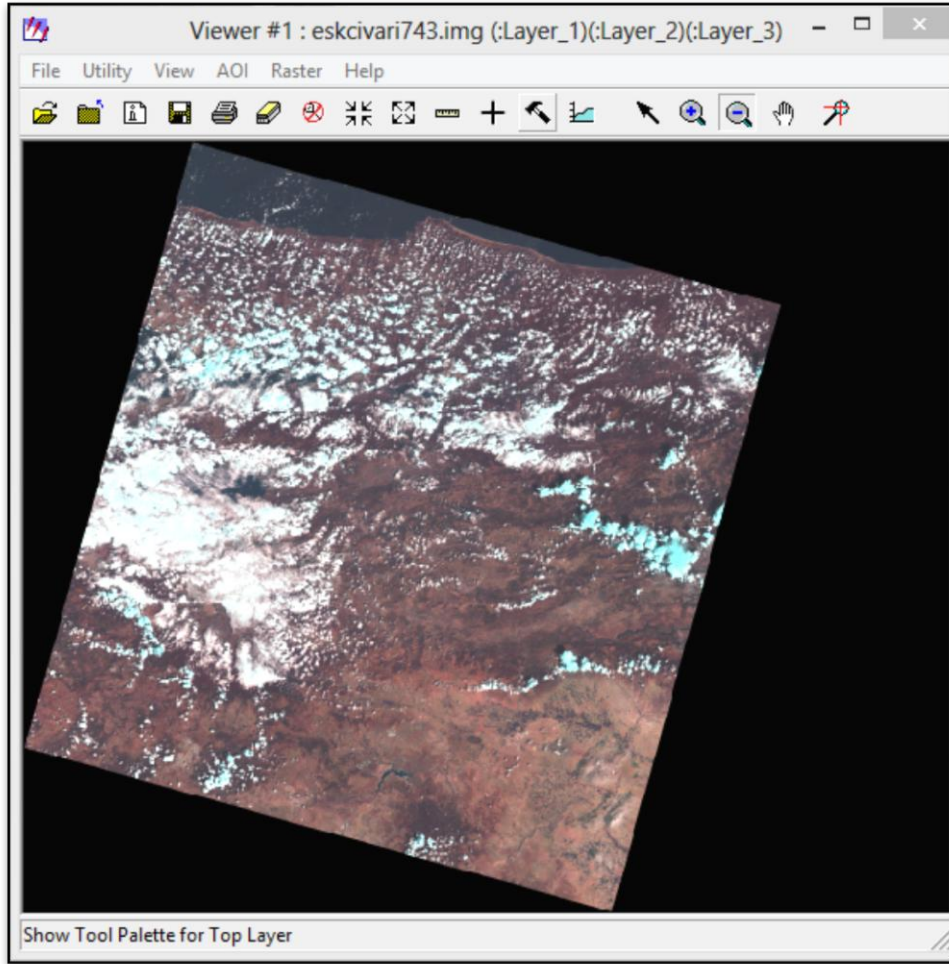
```

elseif P1(p)<P2(p)
    c=2; s=5 ;
else P1(p)==P2(p)
    c=0; s=0;
end
end
disp( '      VERI NO      VERI      P1      P2
SINIF      PARLAKLIK  ');
disp([      p      D(p)  P1(p)  P2(p)  c
s  ]);
A=[s];
fileID = fopen('C:\Users\EMRE\matlab codes\TEZ UYDU
VERI\dukono-2\emduk46.txt','a+');
fprintf(fileID,'%0.0f\n',A);
fclose(fileID);
end
load('C:\Users\EMRE\matlab codes\TEZ UYDU VERI\dukono-
2\emduk46.txt');
y=load('C:\Users\EMRE\matlab codes\TEZ UYDU VERI\dukono-
2\emduk46.txt');
E(:,1)=(reshape(y,58,65));
subplot(3,3,5)
imshow(E(:,1)<45)
imwrite(E(:,1)<45,'C:\Users\EMRE\matlab codes\TEZ UYDU
VERI\dukono-2\emclassb22.tif')

```

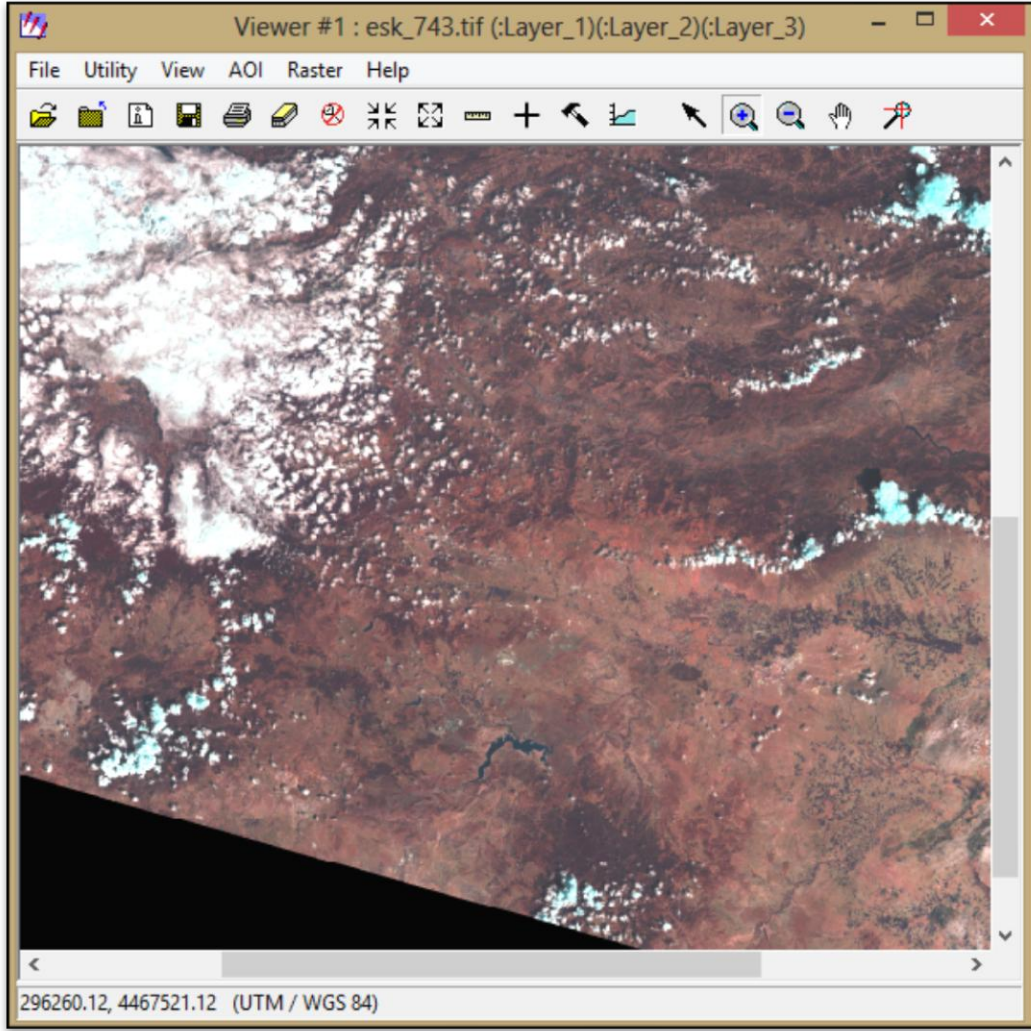
4.2.3. EM Algoritmasının Üç Bantlı İki Bileşenli Uzaktan Algılama Verisine Uygulanması

Bu uygulamada Landsat 8 uydusu için, 7, 4 ve 3 nolu bantlarına ait uydu verisi için Eskişehir ve civarında tahmini iki bileşenli bir yer gerçeği seçilip EM algoritması sonucu parametre tahminleri elde edilecek ve karma modeldeki her bir bileşene ait olasılık yoğunluk fonksiyonu yardımı ile sınıflandırma analizi gerçekleştirilecektir. Kullanılacak uydu verisi ile bu duruma uygun matlab kodu aşağıda verilmiştir:



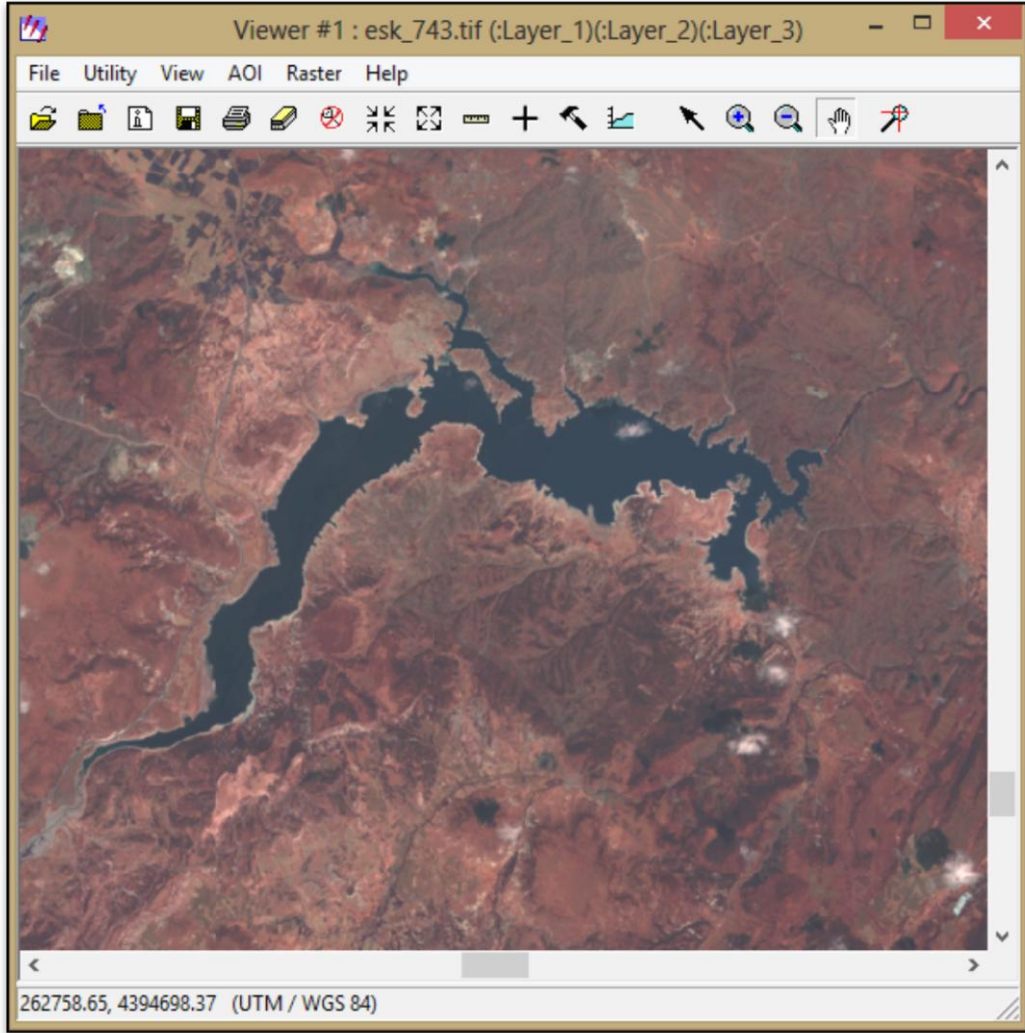
Şekil 4.3. Landsat 8 Eskişehir civarı 7, 4 ve 3 bant kombinasyonlu görüntüsü

Şekil 4.3’de sınıflandırması yapılacak Landsat 8 Eskişehir civarı üç bantlı ve tahmini olarak 2 bileşenli uzaktan algılama verisinin içinde bulunduğu alan verilmiştir.



Şekil 4.4. Landsat 8 Eskişehir civarı 7, 4 ve 3 bant kombinasyonlu seçilen baraj göleti görüntüsü


Şekil 4.4’de sınıflandırması yapılacak Landsat 8 Eskişehir civarı üç bantlı ve tahmini olarak 2 bileşenli uzaktan algılama verisinin içinde bulunduğu alan büyütülmüş olarak gözükmektedir.



Şekil 4.5. Landsat 8 Eskişehir civarı 7, 4 ve 3 bant kombinasyonlu seçilen baraj göleti görüntüsü

Şekil 4.5’de sınıflandırması yapılacak Landsat 8 Eskişehir civarı üç bantlı ve tahmini olarak 2 bileşenli uzaktan algılama verisinin bulunduğu alan yani Porsuk baraj göleti da büyük hali ile verilmiştir.


Bu bölge içerisinde Porsuk baraj göleti bulunmaktadır. Bu bölge UTM/WGS 84 projeksiyon sisteminde koordinatları (257538.12;4391187.43), (258396.01;4391183.28), (258398.09;4390574.05) ve (257539.15;4390578.20) olan alan içerisine bulunmaktadır.



Şekil 4.6. Landsat 8 Eskişehir civarı 7, 4 ve 3 bant kombinasyonlu seçilen Porsuk baraj göletinin bir kısmının görüntüsü

Şekil 4.6'da sınıflandırması yapılacak Landsat 8 Eskişehir civarı üç bantlı ve tahmini olarak 2 bileşenli uzaktan algılama verisinin bulunduğu alan yani Porsuk baraj göletinin içindeki hedef yer gerçeğinin bulunduğu alanın daha büyük hali mevcuttur.

Şekil 4.7'de sınıflandırması yapılacak Landsat 8 Eskişehir civarı üç bantlı ve tahmini olarak 2 bileşenli uzaktan algılama verisinin bulunduğu; yani Porsuk baraj göletinin içindeki hedef yer gerçeği mevcuttur.



Şekil 4.7. Seçilen kısmın büyütülmüş hali

Aşağıda üç bantlı ve tahmini olarak iki bileşenli yani iki sınıflı Şekil 4.7'deki alan için EM algoritması yardımı ile yani Algoritma (2.1)'i kullanan ve karma modele ait her bileşenin olasılık yoğunluk fonksiyonlarının bulunmasını sağlayarak bu sayede sınıflandırma yapan ve sonucu sınıflandırılmış görüntü olarak veren geliştirilmiş modifiyesiz matlab kodu yer almaktadır:

```
% UC BANTLI VE İKİ BİLESENİ UYDU GORUNTUSU İCİN
% EM ALGORİTASI YARDIMIYLA PARAMETRE TAHMİNİ VE
% KARMA OLASILIK YOGUNLUK FONKSİYONLARI BULUNMASI
% VE GORUNTU SINIFLANDIRMASI
% BU KOD EMRE MOLA TARAFINDAN YAZILMISTIR
% ANADOLU UNIVERSİTESİ FEN BİLİMLERİ ENSTİTUSU
% UZAKTAN ALGILAMA VE COĞRAFI BİLGİ SİSTEMLERİ
% DOKTORA TEZİ İCİN GELİSTİRİLMİSTİR
clear all, close all, clc
format long
k=input('Uydu Goruntusundeki Tahmini Kume Sayisini Giriniz=');
x=imread('C:\Users\EMRE\Desktop\DOKTORA
TEZİ\Veriler\EskLandsat_8_3b_2s\eskporsuk3b2s.tif');
dlmwrite('C:\Users\EMRE\Desktop\DOKTORA
TEZİ\Veriler\EskLandsat_8_3b_2s\ASCII\eskporsuk3b2s1.txt',(x(:,:,1)), 'pre
cision', '%.6f')
subplot(4,4,1)
hold on
y1=imshow((x(:,:,1)));
hold off
load('C:\Users\EMRE\Desktop\DOKTORA
TEZİ\Veriler\EskLandsat_8_3b_2s\ASCII\eskporsuk3b2s1.txt');
v1=load('C:\Users\EMRE\Desktop\DOKTORA
TEZİ\Veriler\EskLandsat_8_3b_2s\ASCII\eskporsuk3b2s1.txt');
```

```

    dlmwrite('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat_8_3b_2s\ASCII\eskporsuk3b2s2.txt',(x(:,2)), 'pre
cision', '%.6f')
    subplot(4,4,2)
    hold on
    y2=imshow((x(:,2)));
    hold off
    load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat_8_3b_2s\ASCII\eskporsuk3b2s2.txt');
    v2=load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat_8_3b_2s\ASCII\eskporsuk3b2s2.txt');
    dlmwrite('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat_8_3b_2s\ASCII\eskporsuk3b2s3.txt',(x(:,3)), 'pre
cision', '%.6f')
    subplot(4,4,3)
    hold on
    y3=imshow((x(:,3)));
    hold off
    load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat_8_3b_2s\ASCII\eskporsuk3b2s3.txt');
    v3=load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat_8_3b_2s\ASCII\eskporsuk3b2s3.txt');
    D1=(reshape(v1,609,1));
    D2=(reshape(v2,609,1));
    D3=(reshape(v3,609,1));
    (x(:,1));
    (x(:,2));
    (x(:,3));
    D1;
    D2;
    D3;
options = statset('MaxIter',500)
obj = gmdistribution.fit([D1 D2 D3],k)
ComponentCovariances = obj.Sigma
MixtureProportions = obj.PComponents
MixtureMeans =obj.mu
D=[D1 D2 D3]
%
% EM ALGORITMASI ILE BULUNAN
% KARMA MODEL YARDIMI ILE
% HER BIR PİKSEL İCİN
% OLASILIK KARSILASTIRMALARI
%
%
%
%
P1=obj.PComponents(1)*mvnpdf([D],obj.mu(1,:),(obj.Sigma(:,1)));
P2=obj.PComponents(2)*mvnpdf([D],obj.mu(2,:),(obj.Sigma(:,2)));
for p=1:length(D);
    p
    if (P1(p)>P2(p))
        c=1
    elseif (P2(p)>P1(p))
        c=2
    end
    if (P1(p)>P2(p))
        c=1; s=17; d= fprintf('%d\n',s);
    elseif (P2(p)>P1(p))
        c=2; s=34; d= fprintf('%d\n',s);

```

```

end
fileID = fopen('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat_8_3b_2s\SINIF RENK\eskporsuk3b2s.txt','a+');
fprintf(fileID, '%3.8f\n',s);
fclose(fileID);
end
load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat_8_3b_2s\SINIF RENK\eskporsuk3b2s.txt');
z=load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat_8_3b_2s\SINIF RENK\eskporsuk3b2s.txt');
E(:,:,1)=(reshape(z,21,29));
subplot(4,4,4)
hold on
imshow(E(:,:,1),colormap(prism(275)))
hold off
imwrite(E(:,:,1),'C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat_8_3b_2s\GORUNTU\eskporsuk3b2s.jpeg');
imwrite(E(:,:,1),colormap(prism(250)), 'C:\Users\EMRE\Desktop\DOKTOR
A TEZI\Veriler\EskLandsat_8_3b_2s\GORUNTU\eskporsuk3b2s.tiff');
subplot(4,4,5)
hold on
imshow(E(:,:,1),colormap(prism(250)))
hold off

```

4.2.4. EM Algoritmasının Üç Bantlı ve Üç Bileşenli Uzaktan Algılama Verisine Uygulanması

Bu uygulamada Landsat 8 uydusu için, 7, 4 ve 3 nolu bantlarına ait uydu verisi için Eskişehir civarında tahmini üç bileşenli yer gerçeği seçilip EM algoritması sonucu parametre tahminleri elde edilecek ve karma modeldeki her bir bileşene ait olasılık yoğunluk fonksiyonu yardımı ile sınıflandırma analizi gerçekleştirilecektir. Kullanılacak uydu verisi ile bu duruma uygun matlab kodu aşağıda verilmiştir.

İlgili uydu verisi için Algoritma (2.1)'in çok bileşen durumu için uygulanacaktır. Sınıf sayısı M olmak üzere iki sınıf için Algoritma (2.1)'den türetilen ikiden çok sınıf için Algoritma (2.3) aşağıdadır. Matlab Algoritma (2.1) ve Algoritma (2.3)'e ait formülleri tahmini sınıf sayısı 2 olduğunda Algoritma (2.1) kullanarak ve tahmini sınıf sayısı 2'den fazla olduğunda Algoritma (2.3)'ü kullanarak `obj = gmdistribution.fit` komutu ile yapar:

Algoritma 2.3. İkidenden Çok Bileşenli Gauss Karma Model İçin EM Algoritması

$\theta^T = (p, \mu_1, \sigma_1, \mu_2, \sigma_2)$ olmak üzere parametreleri için ilk tahminlerin yapılması

Beklenti Adımı : Yükümlülüklerin Hesaplanması

$\tilde{p}_i = P(y_i \sim f_1 | \theta)$ olarak tanımlansın, böylece :

$$\tilde{p} = \frac{p f_1(y_i | \theta)}{p f_1(y_i | \theta) + (1-p) f_2(y_i | \theta)} \quad (4.1)$$

böylece:

$$Q(\theta, \theta') = \sum_i \left\{ \tilde{p}_i \left(\log p' - \log \sqrt{2\pi} - \log \sigma_1' - \frac{(y_i - \mu_1')^2}{2\sigma_1'^2} \right) + [(1 - \tilde{p}_i) \log(1 - p') - \log \sqrt{2\pi} - \log \sigma_2' - \frac{(y_i - \mu_2')^2}{2\sigma_2'^2}] \right\} \quad (4.2)$$

En Büyükleme Adımı: Ağırlıklandırılmış ortalamaların ve varyansların hesaplanması : M-Adımı M bileşen için yani 2'den daha çok sınıf için aşağıdaki gibi olur:

$$p_j' = \frac{\sum_i \tilde{p}_{ji}}{n}, \quad 1 \leq j \leq M \quad (4.3)$$

$$\mu_j' = \frac{\sum_i \tilde{p}_{ji} Y_i}{\sum_i \tilde{p}_{ji}}, \quad \text{eğer } 1 \leq j \leq M \quad (4.4)$$

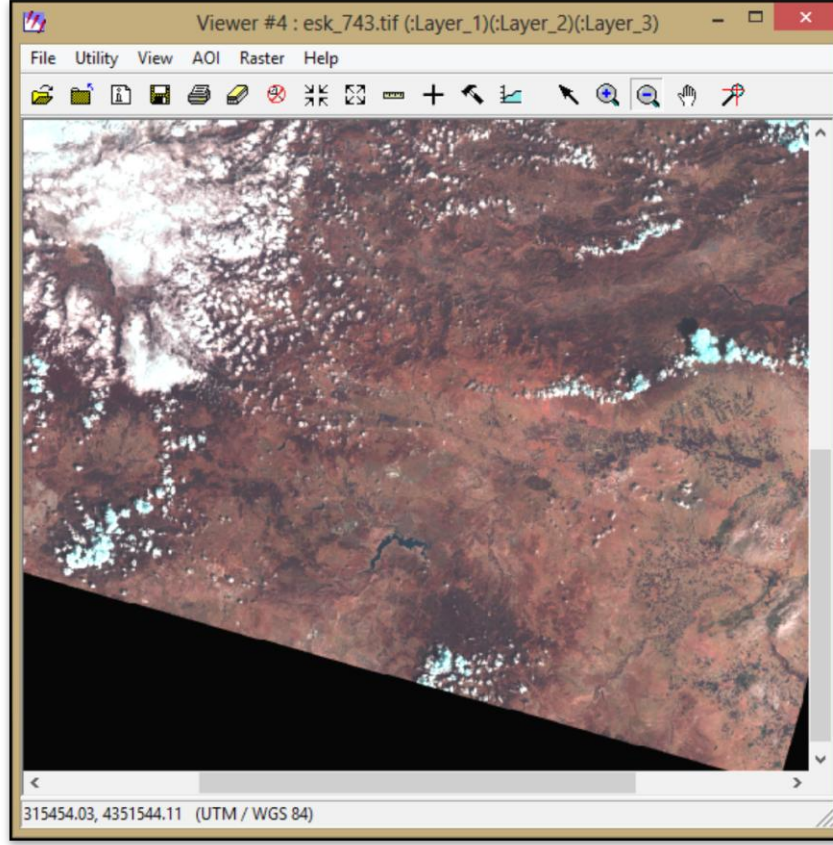
$$\sigma_j' = \sqrt{\frac{\sum_i \tilde{p}_{ji} (Y_i - \mu_j')^2}{\sum_i \tilde{p}_{ji}}}, \quad \text{eğer } 1 \leq j \leq M \quad (4.5)$$

$$\mu_M' = \frac{\sum_i (1 - \sum_{j=1}^{M-1} \tilde{p}_{ji}) Y_i}{\sum_i (1 - \sum_{j=1}^{M-1} \tilde{p}_{ji})} \quad (4.6)$$

$$\sigma_M' = \sqrt{\frac{\sum_i (1 - \sum_{j=1}^{M-1} \tilde{p}_{ji}) (Y_i - \mu_M')^2}{\sum_i (1 - \sum_{j=1}^{M-1} \tilde{p}_{ji})}} \quad (4.7)$$


Adım 2 ve 3 yakınsama olasıya kadar yinelenir.

(Wang 2004).



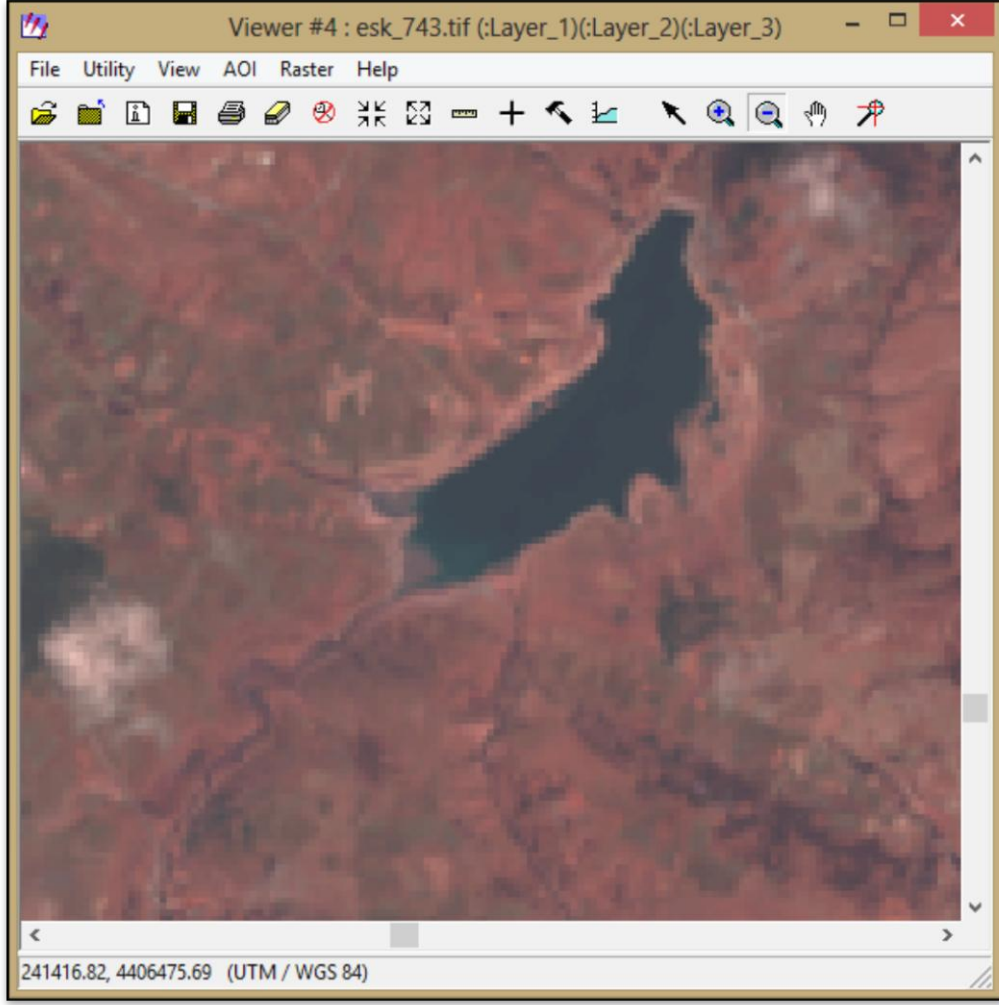
Şekil 4.8. Landsat 8 Eskişehir civarı 7, 4 ve 3 bant kombinasyonlu görüntüsü

Şekil 4.8’de sınıflandırması yapılacak Landsat 8 Eskişehir civarı üç bantlı ve tahmini olarak üç bileşenli uzaktan algılama verisinin içinde bulunduğu alan verilmiştir.




Şekil 4.9. Landsat 8 Eskişehir civarı 7, 4 ve 3 bant kombinasyonlu görüntüsü büyütülmüş hali

Şekil 4.9'da sınıflandırması yapılacak Landsat 8 Eskişehir civarı üç bantlı ve tahmini olarak üç bileşenli uzaktan algılama verisinin içinde bulunduğu alan daha büyük olarak gözükmektedir.



Şekil 4.10. Landsat 8 Eskişehir civarı 7, 4 ve 3 bant kombinasyonlu görüntüsü büyütülmüş hali

Şekil 4.10'da sınıflandırması yapılacak Landsat 8 Eskişehir civarı üç bantlı ve tahmini olarak üç bileşenli uzaktan algılama verisinin içinde bulunduğu hedef alan ve civarı gözükmemektedir.




Şekil 4.11. Seçilen alanın üst köşesi

Şekil 4.11’de sınıflandırması yapılacak Landsat 8 Eskişehir civarı üç bantlı ve tahmini olarak üç bileşenli uzaktan algılama verisinin bulunduğu hedef alanın üst köşesi gözükmektedir.

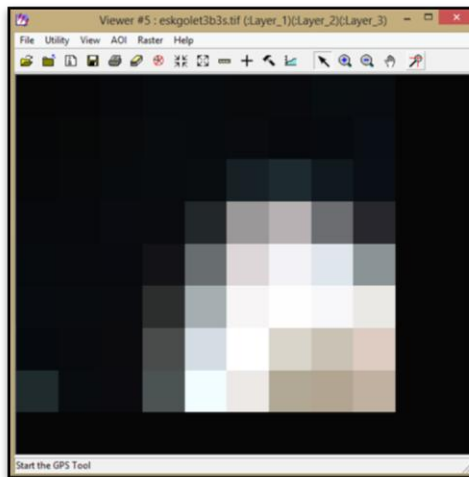
Şekil 4.12’de ise sınıflandırması yapılacak Landsat 8 Eskişehir civarı üç bantlı ve tahmini olarak üç bileşenli uzaktan algılama verisinin bulunduğu hedef alanın alt köşesi gözükmektedir.

Şekil 4.13’de ise sınıflandırması yapılacak Landsat 8 Eskişehir civarı üç bantlı ve tahmini olarak üç bileşenli hedef alan gözükmektedir.

Bu bölge UTM/WGS 84 projeksiyon sisteminde koordinatları (239813.00; 4407935.74), (240078.33;4407936.58), (240078.76;4407699.22) ve (239813.42;4407702.61) olan alan içerisinde bulunmaktadır.



Şekil 4.12. Seçilen alanın alt köşesi



Şekil 4.13. Sınıflandırılması yapılacak alanın büyütülmüş hali

Aşağıda Algoritma (2.3) kullanılarak, üç bantlı ve tahmini olarak üç bileşenli yani üç sınıflı Şekil 4.13'deki alan için EM algoritması yardımı ile yapılan karma modele ait her bileşenin olasılık yoğunluk fonksiyonlarının bulunmasını sağlayarak bu sayede sınıflandırma yapan ve sonucu sınıflandırılmış görüntü olarak veren geliştirilmiş modifiyesiz matlab kodu yer almaktadır:

```
% UC BANTLI VE UC BILESENLI UYDU GORUNTUSU ICIN
% EM ALGORITMASI YARDIMIYLA PARAMETRE TAHMINI VE
% KARMA OLASILIK YOGUNLUK FONKSIYONLARI BULUNMASI
% VE GORUNTU SINIFLANDIRMASI
% BU KOD EMRE MOLA TARAFINDAN YAZILMISTIR
% ANADOLU UNIVERSITESI FEN BILIMLERI ENSTITUSU
% UZAKTAN ALGILAMA VE COGRAFI BILGI SISTEMLERI
% DOKTORA TEZI ICIN GELISTIRILMISTIR
clear all, close all, clc
format long
k=input('Uydu Goruntusundeki Tahmini Kume Sayisini Giriniz=');
x=imread('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_3s\eskgolet3b3s.tif');
dlmwrite('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_3s\ASCII\eskgolet3b3s1.txt',(x(:,:,1)),'precisi
on', '%.6f')
subplot(4,4,1)
hold on
y1=imshow((x(:,:,1)));
hold off
load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_3s\ASCII\eskgolet3b3s1.txt');
v1=load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_3s\ASCII\eskgolet3b3s1.txt');
dlmwrite('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_3s\ASCII\eskgolet3b3s2.txt',(x(:,:,2)),'precisi
on', '%.6f')
subplot(4,4,2)
hold on
y2=imshow((x(:,:,2)));
hold off
load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_3s\ASCII\eskgolet3b3s2.txt');
v2=load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_3s\ASCII\eskgolet3b3s2.txt');
dlmwrite('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_3s\ASCII\eskgolet3b3s3.txt',(x(:,:,3)),'precisi
on', '%.6f')
subplot(4,4,3)
hold on
y3=imshow((x(:,:,3)));
hold off
load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_3s\ASCII\eskgolet3b3s3.txt');
v3=load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_3s\ASCII\eskgolet3b3s3.txt');
D1=(reshape(v1,72,1));
D2=(reshape(v2,72,1));
D3=(reshape(v3,72,1));
```

```

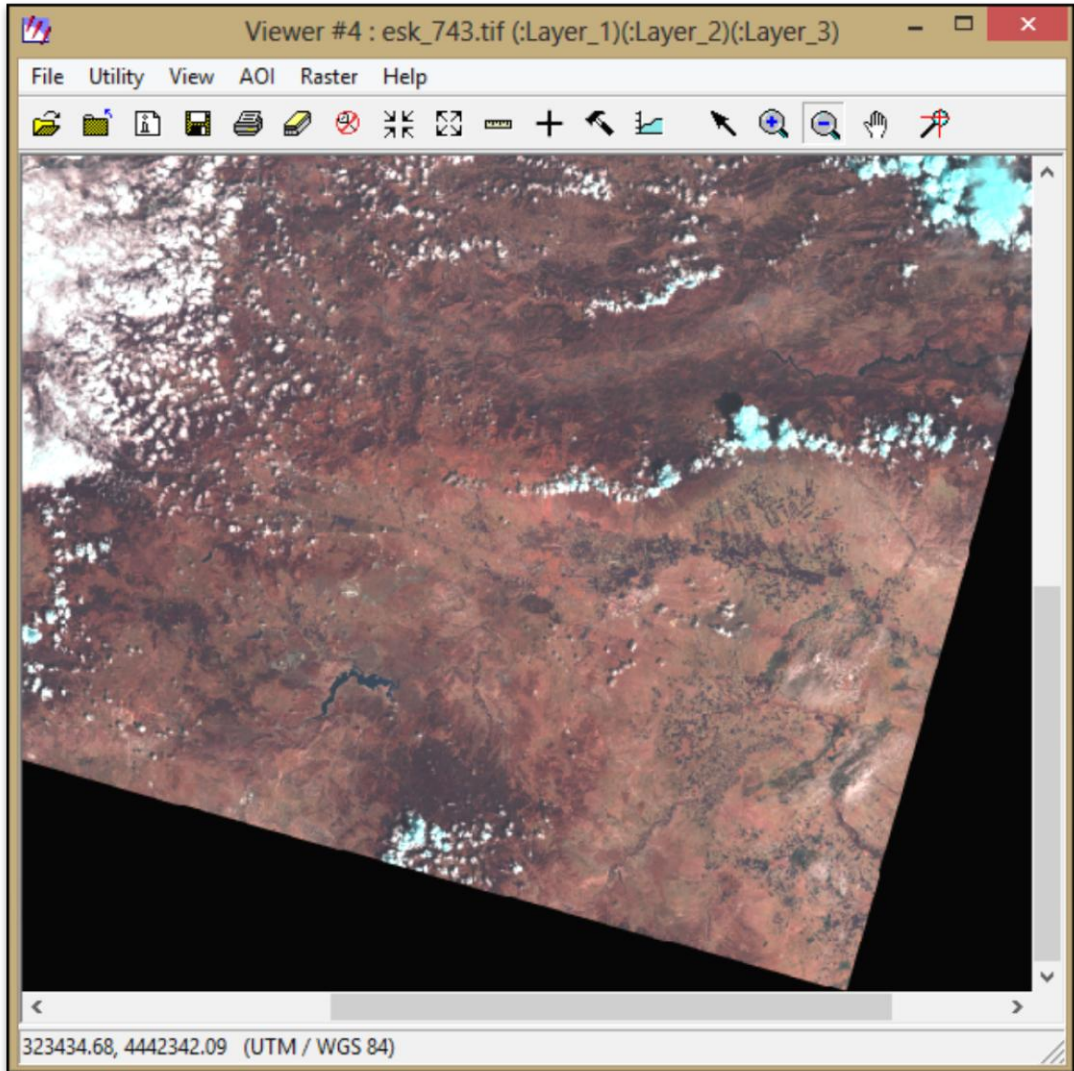
(x(:,:,1));
(x(:,:,2));
(x(:,:,3));
D1;
D2;
D3;
options = statset('MaxIter',500)
obj = gmdistribution.fit([D1 D2 D3],k)
ComponentCovariances = obj.Sigma
MixtureProportions = obj.PComponents
MixtureMeans =obj.mu
D=[D1 D2 D3]
%
% EM ALGORITMASI ILE BULUNAN
% KARMA MODEL YARDIMI ILE
% HER BIR PİKSEL ICIN
% OLASILIK KARSILASTIRMALARI
%
%
%
%
P1=obj.PComponents(1)*mvnpdf([D],obj.mu(1,:,:),(obj.Sigma(:,:,1)));
P2=obj.PComponents(2)*mvnpdf([D],obj.mu(2,:,:),(obj.Sigma(:,:,2)));
P3=obj.PComponents(3)*mvnpdf([D],obj.mu(3,:,:),(obj.Sigma(:,:,3)));
for p=1:1:length(D);
    p
    if (P1(p)>P2(p))&&(P1(p)>P3(p))
        c=1
    elseif (P2(p)>P1(p))&&(P2(p)>P3(p))
        c=2
    elseif (P3(p)>P1(p))&&(P3(p)>P2(p))
        c=3
    end
    if (P1(p)>P2(p))&&(P1(p)>P3(p))
        c=1; s=17; d= fprintf('%d\n',s);
    elseif (P2(p)>P1(p))&&(P2(p)>P3(p))
        c=2; s=34; d= fprintf('%d\n',s);
    elseif (P3(p)>P1(p))&&(P3(p)>P2(p))
        c=3; s=51; d= fprintf('%d\n',s);
    end
    fileID = fopen('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_3s\SINIF RENK\eskolet3b3s.txt','a+');
    fprintf(fileID, '%3.8f\n',s);
    fclose(fileID);
end
load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_3s\SINIF RENK\eskolet3b3s.txt');
z=load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_3s\SINIF RENK\eskolet3b3s.txt');
E(:,:,1)=(reshape(z,8,9));
subplot(4,4,4)
hold on
imshow(E(:,:,1),colormap(prism(275)))
hold off
imwrite(E(:,:,1),colormap(prism(250)), 'C:\Users\EMRE\Desktop\DOKTOR
A TEZI\Veriler\EskLandsat8_3b_3s\GORUNTU\eskolet3b3s.tif');
imwrite(E(:,:,1),colormap(prism(250)), 'C:\Users\EMRE\Desktop\DOKTOR
A TEZI\Veriler\EskLandsat8_3b_3s\GORUNTU\eskolet3b3s.jpeg');
subplot(4,4,5)

```

```
hold on
imshow(E(:,:,1),colormap(prism(250)))
hold off
```


4.2.5. EM Algoritmasının Üç Bantlı ve Dört Bileşenli Uzaktan Algılama Verisine Uygulanması

Bu uygulamada Landsat 8 uydusu için, 7, 4 ve 3 nolu bantlarına ait uydu görüntü verisi Eskişehir ve civarında tahmini dört bileşenli bir yer gerçeği seçilip EM algoritması sonucu parametre tahminleri elde edilecek ve karma modeldeki her bir bileşene ait olasılık yoğunluk fonksiyonu yardımı ile sınıflandırma analizi gerçekleştirilecektir. Kullanılacak uydu verisi ile bu duruma uygun matlab kodu aşağıda verilmiştir:



Şekil 4.14. Sınıflandırılması yapılacak alanın büyütülmüş hali

Şekil 4.14’de sınıflandırması yapılacak Landsat 8 Eskişehir civarı üç bantlı ve tahmini olarak dört bileşenli uzaktan algılama verisinin içinde bulunduğu alan verilmiştir.




Şekil 4.15. Sınıflandırılması yapılacak alanın büyütülmüş hali

Şekil 4.15’de sınıflandırması yapılacak Landsat 8 Eskişehir civarı üç bantlı ve tahmini olarak dört bileşenli uzaktan algılama verisinin bulunduğu alanın büyük hali verilmiştir.


Şekil 4.16’da sınıflandırması yapılacak Landsat 8 Eskişehir civarı üç bantlı ve tahmini olarak dört bileşenli uzaktan algılama verisinin bulunduğu alanın daha büyük hali verilmiştir.

Şekil 4.17’de sınıflandırması yapılacak Landsat 8 Eskişehir civarı üç bantlı ve tahmini olarak dört bileşenli alan verilmiştir.



Şekil 4.16. Sınıflandırılması yapılacak alanın büyütülmüş hali

Bu bölge içerisinde Porsuk baraj göleti bulunmaktadır. Bu bölge UTM/WGS 84 projeksiyon sisteminde koordinatları (238031.66; 4408118.40), (239619.73;4408115.58), (239618.32;4407272.09) ve (238027.42;4407273.51) olan alan içerisinde bulunmaktadır.



Şekil 4.17. Sınıflandırılması yapılacak alanın büyütülmüş hali

Aşağıda Aşağıda Algoritma (2.3) kullanılarak, üç bantlı ve tahmini olarak dört bileşenli yani dört sınıflı Şekil 4.17'deki alan için EM algoritması yardımı ile yapılan karma modele ait her bileşenin olasılık yoğunluk fonksiyonlarının bulunmasını sağlayarak bu sayede sınıflandırma yapan ve sonucu sınıflandırılmış görüntü olarak veren geliştirilmiş modifiyesiz matlab kodu yer almaktadır:

```
% UC BANTLI VE DORT BILESENLI UYDU GORUNTUSU ICIN
% EM ALGORITMASI YARDIMIYLA PARAMETRE TAHMINI VE
% KARMA OLASILIK YOGUNLUK FONKSIYONLARI BULUNMASI
% VE GORUNTU SINIFLANDIRMASI
% BU KOD EMRE MOLA TARAFINDAN YAZILMISTIR
% ANADOLU UNIVERSITESI FEN BILIMLERI ENSTITUSU
% UZAKTAN ALGILAMA VE COGRAFI BILGI SISTEMLERI
% DOKTORA TEZI ICIN GELISTIRILMISTIR
clear all, close all, clc
format long
k=input('Uydu Goruntusundeki Tahmini Kume Sayisini Giriniz=');
x=imread('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_4s\eskgol3b4s.tif');
dlmwrite('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_4s\ASCII\eskgol3b4s1.txt',(x(:,1)), 'precision', '%.6f')
subplot(4,4,1)
hold on
y1=imshow((x(:,1)));
hold off
load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_4s\ASCII\eskgol3b4s1.txt');
v1=load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_4s\ASCII\eskgol3b4s1.txt');
dlmwrite('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_4s\ASCII\eskgol3b4s2.txt',(x(:,2)), 'precision', '%.6f')
subplot(4,4,2)
hold on
y2=imshow((x(:,2)));
hold off
load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_4s\ASCII\eskgol3b4s2.txt');
v2=load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_4s\ASCII\eskgol3b4s2.txt');
dlmwrite('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_4s\ASCII\eskgol3b4s3.txt',(x(:,3)), 'precision', '%.6f')
subplot(4,4,3)
hold on
y3=imshow((x(:,3)));
hold off
load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_4s\ASCII\eskgol3b4s3.txt');
v3=load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_4s\ASCII\eskgol3b4s3.txt');
D1=(reshape(v1,1566,1));
```

```

D2=(reshape(v2,1566,1));
D3=(reshape(v3,1566,1));
(x(:,1));
(x(:,2));
(x(:,3));
D1;
D2;
D3;
options = statset('MaxIter',500)
obj = gmdistribution.fit([D1 D2 D3],k)
ComponentCovariances = obj.Sigma
MixtureProportions = obj.PComponents
MixtureMeans =obj.mu
D=[D1 D2 D3]
%
% EM ALGORITMASI ILE BULUNAN
% KARMA MODEL YARDIMI ILE
% HER BIR PİKSEL İCİN
% OLASILIK KARSILASTIRMALARI
%
%
%
%
P1=obj.PComponents(1)*mvnpdf([D],obj.mu(1,:),(obj.Sigma(:,1)));
P2=obj.PComponents(2)*mvnpdf([D],obj.mu(2,:),(obj.Sigma(:,2)));
P3=obj.PComponents(3)*mvnpdf([D],obj.mu(3,:),(obj.Sigma(:,3)));
P4=obj.PComponents(4)*mvnpdf([D],obj.mu(4,:),(obj.Sigma(:,4)));
for p=1:1:length(D);
p
if (P1(p)>P2(p))&&(P1(p)>P3(p))&&(P1(p)>P4(p))
c=1
elseif (P2(p)>P1(p))&&(P2(p)>P3(p))&&(P2(p)>P4(p))
c=2
elseif (P3(p)>P1(p))&&(P3(p)>P2(p))&&(P3(p)>P4(p))
c=3
elseif (P4(p)>P1(p))&&(P4(p)>P2(p))&&(P4(p)>P3(p))
c=4
end
if (P1(p)>P2(p))&&(P1(p)>P3(p))&&(P1(p)>P4(p))
c=1; s=17; d= fprintf('%d\n',s);
elseif (P2(p)>P1(p))&&(P2(p)>P3(p))&&(P2(p)>P4(p))
c=2; s=34; d= fprintf('%d\n',s);
elseif (P3(p)>P1(p))&&(P3(p)>P2(p))&&(P3(p)>P4(p))
c=3; s=51; d= fprintf('%d\n',s);
elseif (P4(p)>P1(p))&&(P4(p)>P2(p))&&(P4(p)>P3(p))
c=4; s=68; d= fprintf('%d\n',s);
end
fileID = fopen('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_4s\SINIF RENK\eskgol3b4s.txt','a+');
fprintf(fileID,'%3.8f\n',s);
fclose(fileID);
end
load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_4s\SINIF RENK\eskgol3b4s.txt');
z=load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_4s\SINIF RENK\eskgol3b4s.txt');
E(:,1)=(reshape(z,29,54));
subplot(4,4,4)
hold on

```

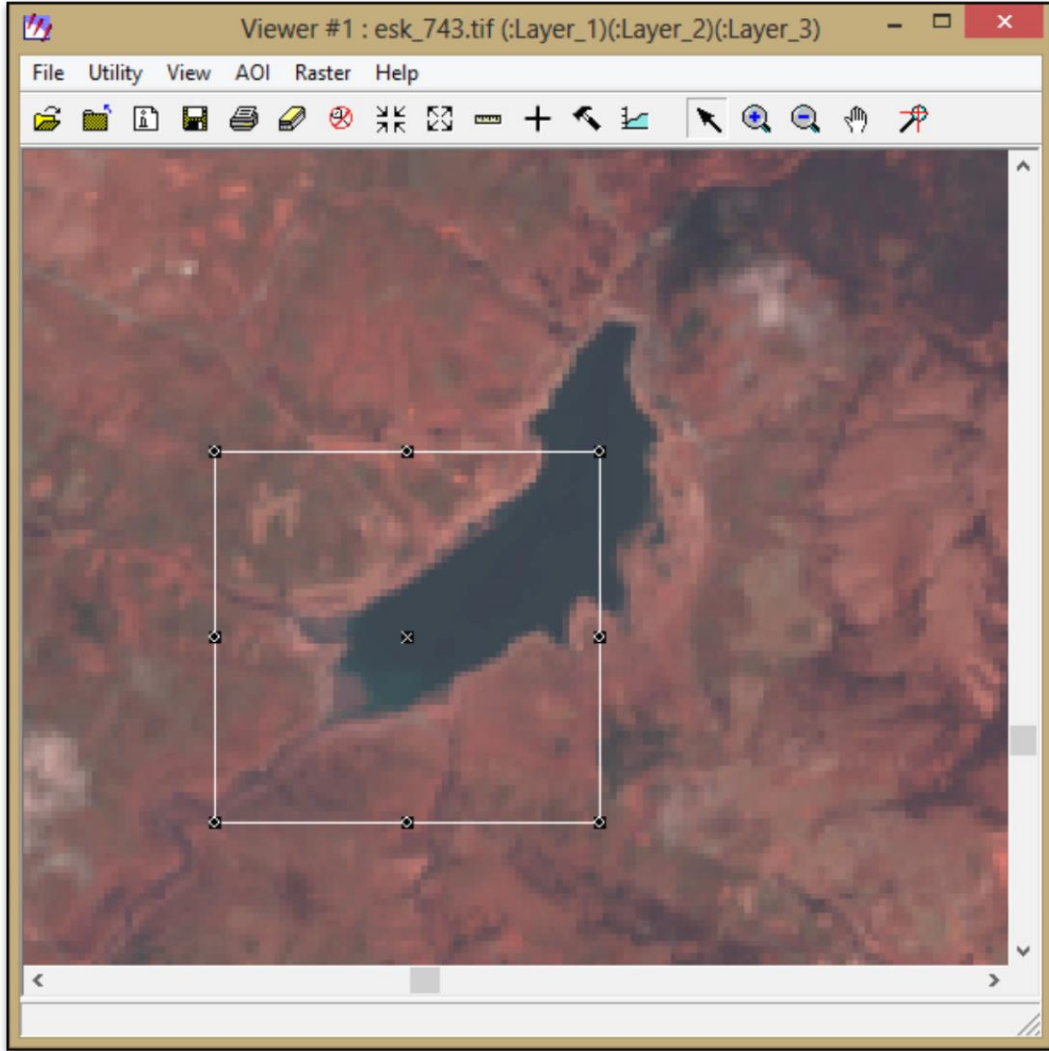
```
imshow(E(:,:,1),colormap(prism(275)))  
hold off  
imwrite(E(:,:,1),colormap(prism(250)), 'C:\Users\EMRE\Desktop\DOKTOR  
A TEZI\Veriler\EskLandsat8_3b_4s\GORUNTU\eskgol3b4s.tif');  
imwrite(E(:,:,1),colormap(prism(250)), 'C:\Users\EMRE\Desktop\DOKTOR  
A TEZI\Veriler\EskLandsat8_3b_4s\GORUNTU\eskgol3b4s.jpeg');  
subplot(4,4,5)  
hold on  
imshow(E(:,:,1),colormap(prism(250)))  
hold off
```

4.2.6. EM Algoritmasının Üç Bantlı Beş Bileşenli Uzaktan Algılama Verisine Uygulanması


Bu uygulamada Landsat 8 uydusu için, 7, 4 ve 3 nolu bantlarına ait uydu verisi Eskişehir civarında tahmini beş bileşenli bir yer gerçeği seçilip EM algoritması sonucu parametre tahminleri elde edilecek ve karma modeldeki her bir bileşene ait olasılık yoğunluk fonksiyonu yardımı ile sınıflandırma analizi gerçekleştirilecektir. Kullanılacak uydu verisi ile bu duruma uygun matlab kodu aşağıda verilmiştir.

Şekil 4.18’de sınıflandırması yapılacak Landsat 8 Eskişehir civarı üç bantlı ve tahmini olarak beş bileşenli uzaktan algılama verisinin bulunduğu alanın büyük hali verilmiştir. Şekil 4.19’da sınıflandırması yapılacak Landsat 8 Eskişehir civarı üç bantlı ve tahmini olarak beş bileşenli alan verilmiştir.

Bu bölge UTM/WGS 84 projeksiyon sisteminde koordinatları (238308.54; 4408421.75), (240022.26; 4408417.00), (240018.12;4407157.70) ve (238308.54 ;4407157.70) olan alan içerisine bulunmaktadır.



Şekil 4.18. Sınıflandırılması yapılacak uydu verisi



Şekil 4.19. Sınıflandırılması yapılacak uydu verisinin büyütülmüş hali

Aşağıda Algoritma (2.3) kullanılarak, üç bantlı ve tahmini olarak beş bileşenli yani beş sınıflı Şekil 4.19'daki alan için EM algoritması yardımı ile yapılan karma modele ait her bileşenin olasılık yoğunluk fonksiyonlarının bulunmasını sağlayarak bu sayede sınıflandırma yapan ve sonucu sınıflandırılmış görüntü olarak veren geliştirilmiş modifiyesiz matlab kodu yer almaktadır:

```
% UC BANTLI VE BES BILESENLI UYDU VERISI ICIN
% EM ALGORITMASI YARDIMIYLA PARAMETRE TAHMINI VE
% KARMA OLASILIK YOGUNLUK FONKSIYONLARI BULUNMASI
% VE GORUNTU SINIFLANDIRMASI
% BU KOD EMRE MOLA TARAFINDAN YAZILMISTIR
% ANADOLU UNIVERSITESI FEN BILIMLERI ENSTITUSU
% UZAKTAN ALGILAMA VE COGRAFI BILGI SISTEMLERI
% DOKTORA TEZI ICIN GELISTIRILMISTIR
clear all, close all, clc
format long
k=input('Uydu Goruntusundeki Tahmini Kume Sayisini Giriniz=');
x=imread('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_5s\3b5s.tif');
dlmwrite('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_5s\ASCII\3b5s1.txt',(x(:,1)), 'precision', '%.6
f)
subplot(4,4,1)
hold on
y1=imshow((x(:,1)));
hold off
load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_5s\ASCII\3b5s1.txt');
v1=load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_5s\ASCII\3b5s1.txt');
dlmwrite('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_5s\ASCII\3b5s2.txt',(x(:,2)), 'precision', '%.6
f)
subplot(4,4,2)
hold on
y2=imshow((x(:,2)));
hold off
load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_5s\ASCII\3b5s2.txt');
v2=load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_5s\ASCII\3b5s2.txt');
dlmwrite('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_5s\ASCII\3b5s3.txt',(x(:,3)), 'precision', '%.6
f)
subplot(4,4,3)
hold on
y3=imshow((x(:,3)));
hold off
load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_5s\ASCII\3b5s3.txt');
v3=load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_5s\ASCII\3b5s3.txt');
D1=(reshape(v1,2494,1));
D2=(reshape(v2,2494,1));
D3=(reshape(v3,2494,1));
```

```

(x(:,:,1));
(x(:,:,2));
(x(:,:,3));
D1;
D2;
D3;
options = statset('MaxIter',500)
obj = gmdistribution.fit([D1 D2 D3],k)
ComponentCovariances = obj.Sigma
MixtureProportions = obj.PComponents
MixtureMeans = obj.mu
D=[D1 D2 D3]
%
% EM ALGORITMASI ILE BULUNAN
% KARMA MODEL YARDIMI ILE
% HER BIR PİKSEL İCİN
% OLASILIK KARSILASTIRMALARI
%
%
%
%
P1=obj.PComponents(1)*mvnpdf([D],obj.mu(1,:,:),(obj.Sigma(:,:,1)));
P2=obj.PComponents(2)*mvnpdf([D],obj.mu(2,:,:),(obj.Sigma(:,:,2)));
P3=obj.PComponents(3)*mvnpdf([D],obj.mu(3,:,:),(obj.Sigma(:,:,3)));
P4=obj.PComponents(4)*mvnpdf([D],obj.mu(4,:,:),(obj.Sigma(:,:,4)));
P5=obj.PComponents(5)*mvnpdf([D],obj.mu(5,:,:),(obj.Sigma(:,:,5)));
for p=1:1:length(D);
    p
    if (P1(p)>P2(p))&&(P1(p)>P3(p))&&(P1(p)>P4(p))&&(P1(p)>P5(p))
        c=1
    elseif (P2(p)>P1(p))&&(P2(p)>P3(p))&&(P2(p)>P4(p))&&(P2(p)>P5(p))
        c=2
    elseif (P3(p)>P1(p))&&(P3(p)>P2(p))&&(P3(p)>P4(p))&&(P3(p)>P5(p))
        c=3
    elseif (P4(p)>P1(p))&&(P4(p)>P2(p))&&(P4(p)>P3(p))&&(P4(p)>P5(p))
        c=4
    elseif (P5(p)>P1(p))&&(P5(p)>P2(p))&&(P5(p)>P3(p))&&(P5(p)>P4(p))
        c=5
    elseif
(P6(p)>P1(p))&&(P6(p)>P2(p))&&(P6(p)>P3(p))&&(P6(p)>P4(p))
    end
    if (P1(p)>P2(p))&&(P1(p)>P3(p))&&(P1(p)>P4(p))&&(P1(p)>P5(p))
        c=1; s=17; d= fprintf('%d\n',s);
    elseif (P2(p)>P1(p))&&(P2(p)>P3(p))&&(P2(p)>P4(p))&&(P2(p)>P5(p))
        c=2; s=34; d= fprintf('%d\n',s);
    elseif (P3(p)>P1(p))&&(P3(p)>P2(p))&&(P3(p)>P4(p))&&(P3(p)>P5(p))
        c=3; s=51; d= fprintf('%d\n',s);
    elseif (P4(p)>P1(p))&&(P4(p)>P2(p))&&(P4(p)>P3(p))&&(P4(p)>P5(p))
        c=4; s=68; d= fprintf('%d\n',s);
    elseif (P5(p)>P1(p))&&(P5(p)>P2(p))&&(P5(p)>P3(p))&&(P5(p)>P4(p))
        c=5; s=85; d= fprintf('%d\n',s);
    end
    fileID = fopen('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_5s\SINIF RENK\3b5s.txt','a+');
    fprintf(fileID,'%3.8f\n',s);
    fclose(fileID);
end
load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_5s\SINIF RENK\3b5s.txt');

```

```

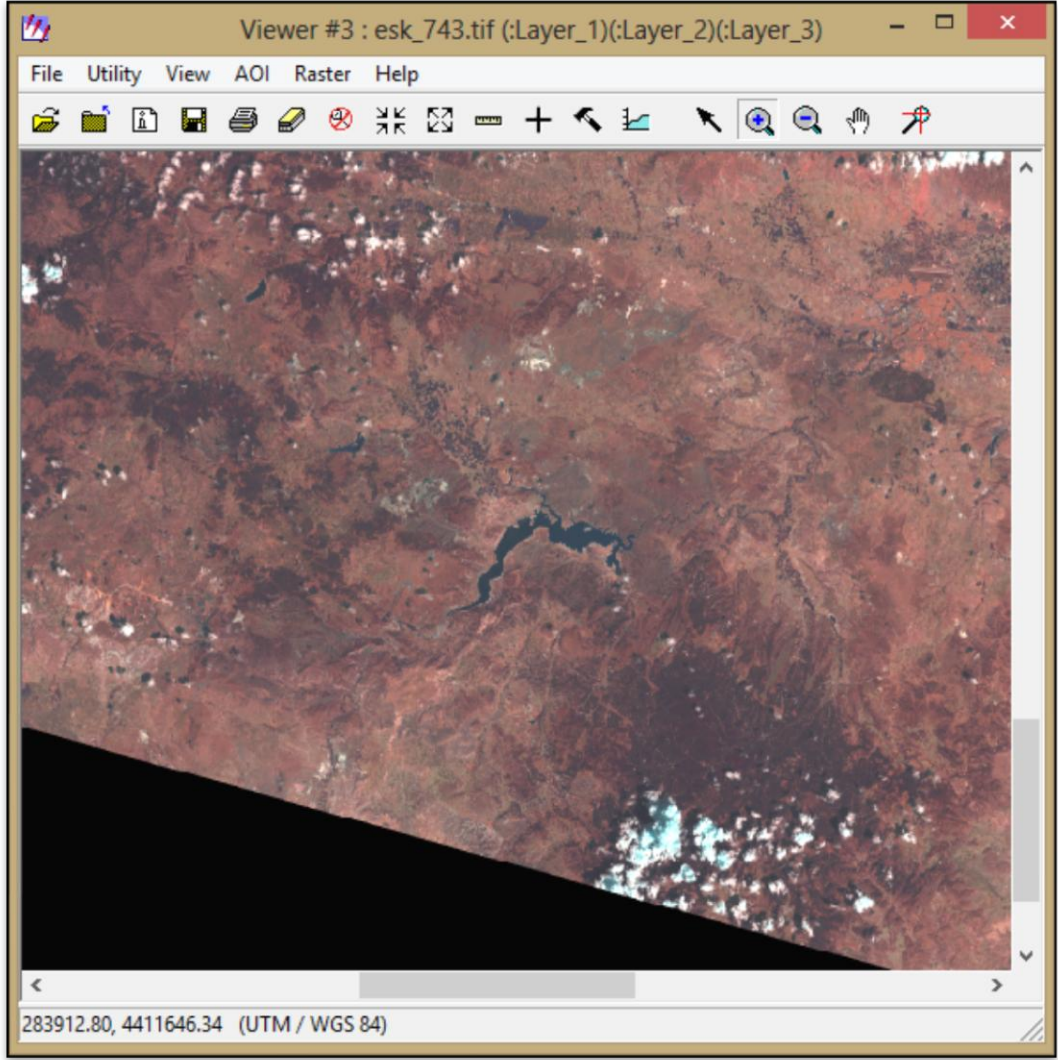
z=load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_5s\SINIF RENK\3b5s.txt');
E(:,:,1)=(reshape(z,43,58));
subplot(4,4,4)
hold on
imshow(E(:,:,1),colormap(prism(275)))
hold off
imwrite(E(:,:,1),colormap(prism(250)), 'C:\Users\EMRE\Desktop\DOKTOR
A TEZI\Veriler\EskLandsat8_3b_5s\GORUNTU\3b5s.tif');
imwrite(E(:,:,1),colormap(prism(250)), 'C:\Users\EMRE\Desktop\DOKTOR
A TEZI\Veriler\EskLandsat8_3b_5s\GORUNTU\3b5s.jpeg');
subplot(4,4,5)
hold on
imshow(E(:,:,1),colormap(prism(250)))
hold off

```

4.2.7. Modifiye EM Algoritmasının Üç Bant ve 15 Bileşenli Uzaktan Algılama Verisine Uygulanması

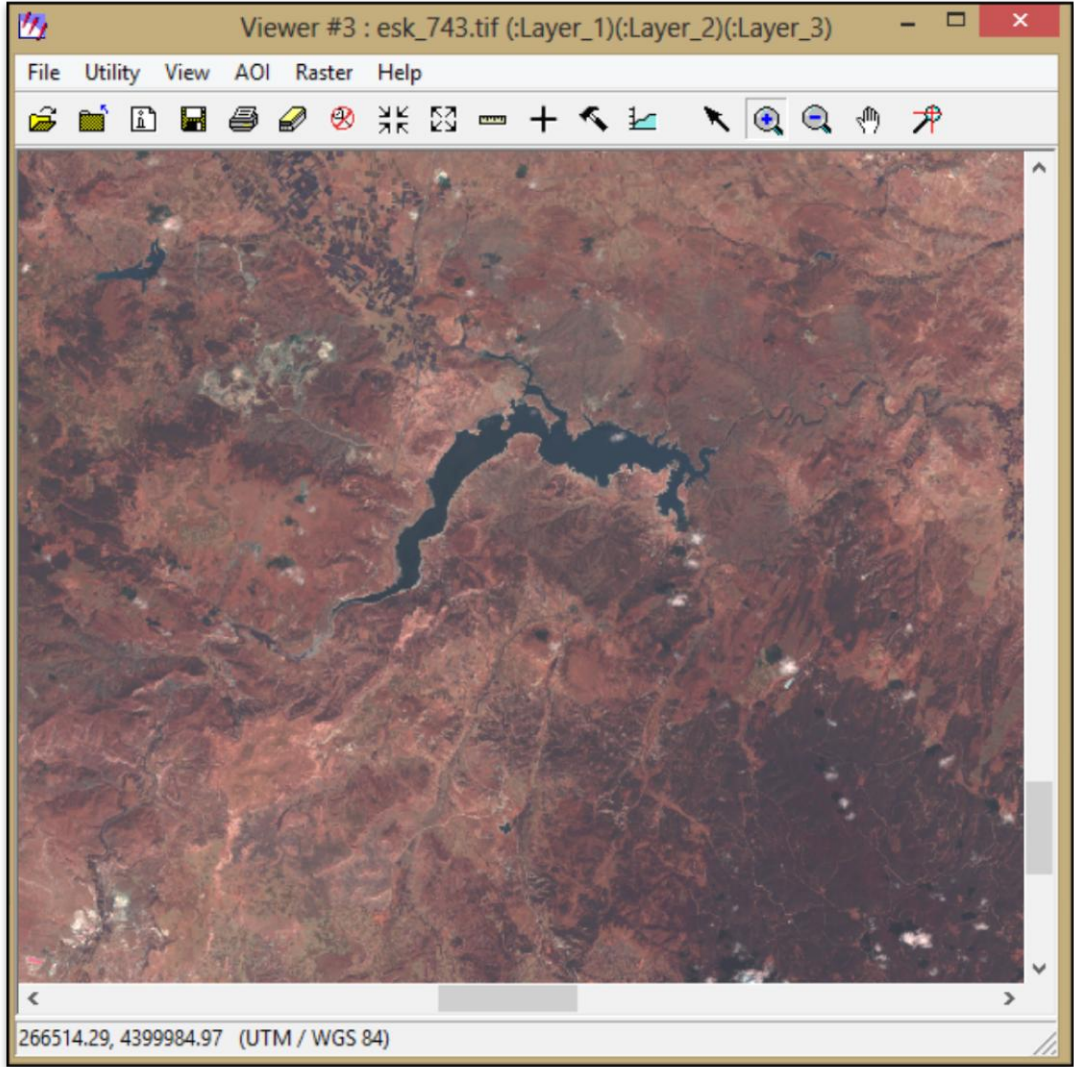
Bu uygulamada Landsat 8 uydusu için, 7, 4 ve 3 nolu bantlarına ait uydu görüntü verisi Eskişehir civarında tahmini sınıf sayısı 15 olan yer gerçeğine ait uydu verisi görüntüsü seçilip modifiye edilmiş EM algoritması sonucu parametre tahminleri elde edilecek ve karma modeldeki her bir bileşene ait olasılık yoğunluk fonksiyonu yardımı ile sınıflandırma analizi gerçekleştirilecektir. Kullanılacak uydu verisi ile bu duruma uygun matlab kodu aşağıda verilmiştir.

Bu uygulamada Landsat 8 uydusu için 7, 4 ve 3 nolu bantlarına ait Eskişehir civarında bulunan Porsuk baraj göleti ve etrafına ait uydu verisine modifiye EM algoritması uygulanacaktır.



Şekil 4.20. Sınıflandırması yapılacak Landsat 8 Eskişehir civarı 7, 4 ve 3 bant kombinasyonlu Porsuk baraj göleti uydu verisi

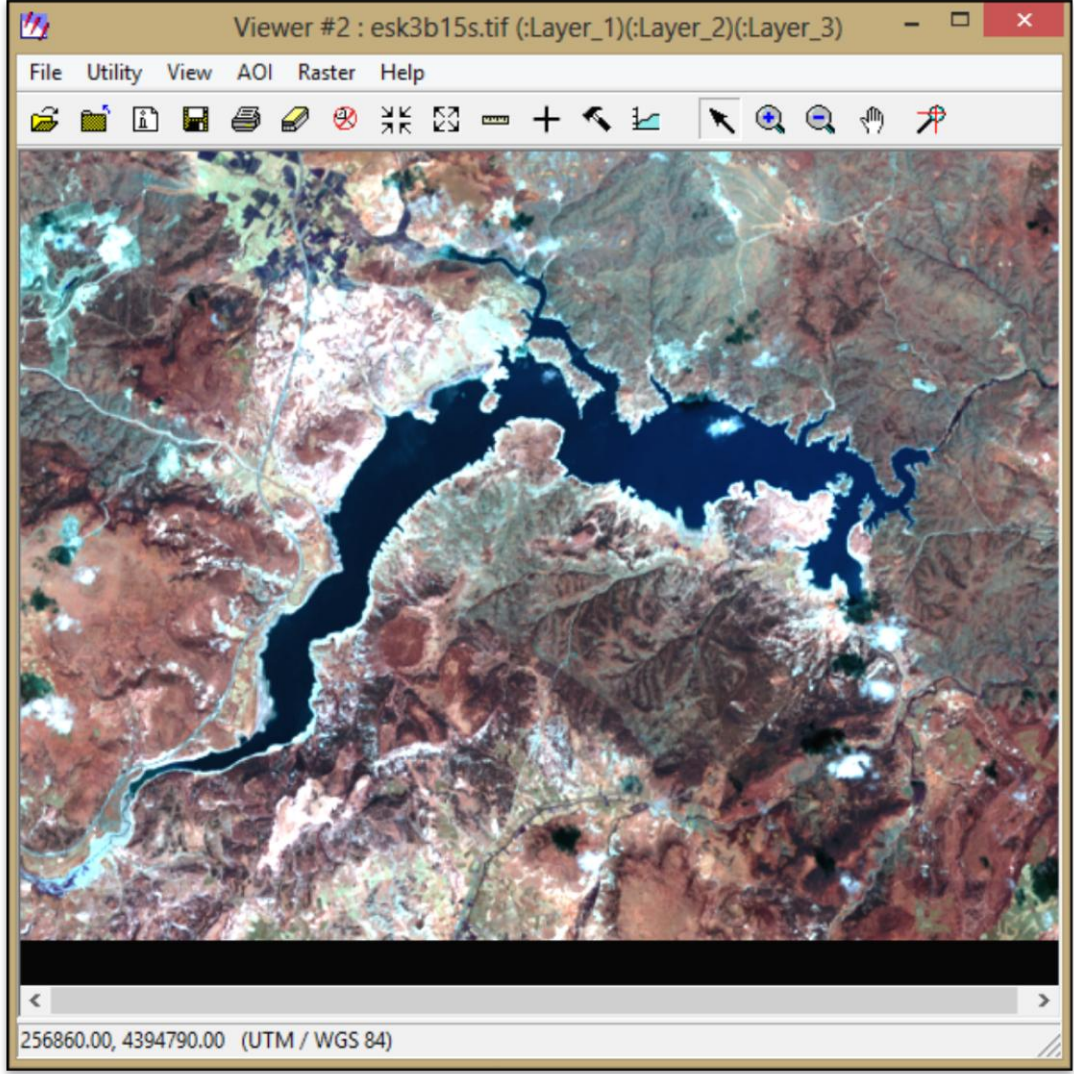
Şekil 4.20’de sınıflandırması yapılacak Landsat 8 Eskişehir civarı üç bantlı ve tahmini olarak 15 bileşenli uzaktan algılama verisinin bulunduğu alan gösterilmiştir. Şekil 4.21’de sınıflandırması yapılacak Landsat 8 Eskişehir civarı üç bantlı ve tahmini olarak 15 bileşenli alanın daha büyük hali verilmiştir.



Şekil 4.21. Sınıflandırması yapılacak Landsat 8 Eskişehir civarı 7, 4 ve 3 bant kombinasyonlu Porsuk baraj göleti uydu verisinin daha büyük hali

Şekil 4.22’de sınıflandırması yapılacak Landsat 8 Eskişehir civarı üç bantlı ve tahmini olarak 15 bileşenli alan verilmiştir.

Bu bölge UTM/WGS 84 projeksiyon sisteminde koordinatları (251370.00; 4395870.00), (268860.00;4395780.00), (251310.00;4382850.00) ve (268800.00;4382820.00) olan alan içerisinde bulunmaktadır.



Şekil 4.22. Sınıflandırması yapılacak uydu verisi

İlgili uydu görüntü verisi için Algoritma (2.3) uygulanacaktır. Algoritma (2.1)'den türetilerek çok sınıf için elde edilen Algoritma (2.3) göz önüne alınarak, geliştirilen 15 sınıf için 3 bantlı modifiye edilmiş EM algoritması matlab kodu aşağıdadır. Ters olmayan karesel matrisler, tekil matrisler olarak adlandırılırlar. Bazı durumlarda, bir ya da daha fazla bileşen yani sınıf, tekil ya da tekile yakın varyans-kovaryans matrisi içerebilir. İşte Şekil 4.22'deki uzaktan algılama verisi sınıflandırılmaya çalışılırken, bir ya da birden daha fazla bileşene ait varyans-kovaryans matrisinin tekillik sorunu nedeni ile EM algoritması iterasyonu tamamlayıp yakınsamaya geçememiş dolayısı ile 15 sınıf için karma model oluşturulamamış ve bu yüzden parametre tahminleri yapılamadığı için sınıflandırma işlemi gerçekleşmemiştir.

Buna rağmen, bu sorunun üstesinden geliştirilen modifiye EM algoritması düzenlenerek matlab kodunda devreye sokulduğunda varyans kovaryans matrisi tekilik tuzağından kurtularak EM algoritması iterasyonu tamamlayıp yakınsamaya geçmiş ve dolayısı ile 15 sınıf için karma model oluşturulmuş böylece 15 sınıfa ait parametre tahminleri ve dolayısı ile karma olasılık yoğunluk fonksiyonları oluşturularak sınıflandırma işlemi yapılmıştır. Matlab'ın yardım menüsüne göre; "Regularize" negatif olmayan "regularization" değeri her bir varyans-kovaryans matrisinin köşegenine atanarak tahminlerin pozitif tanımlı olduğundan emin olunur ve varsayılan değer 0 dır. Üç bant ve tahmini 15 sınıf için varyans-kovaryans matrisi ya da matrislerini tekilik sorunundan kurtaran düzenleme yani "Regularize" komutu aşağıdaki gibidir:

```
obj = gmdistribution.fit([D1 D2 D3],k,'Options',options,'Regularize',1e-50);
```

Böylece EM algoritması 10^{-50} hassaslık seviyesinde modifiye edilmiş olunur. Aşağıda üç bantlı ve tahmini olarak 15 bileşenli yani 15 sınıflı Şekil 4.22'deki alan için EM algoritması yardımı ile yapılan karma modele ait her bileşenin olasılık yoğunluk fonksiyonlarının bulunmasını sağlayarak bu sayede sınıflandırma yapan ve sonucu sınıflandırılmış görüntü olarak veren geliştirilmiş modifiyeli matlab kodu yer almaktadır:

```
% UC BANTLI VE BES BILESENLI UYDU VERISI ICIN
% MODIFIYE EM ALGORITMASI YARDIMIYLA PARAMETRE
TAHMINI VE
% KARMA OLASILIK YOGUNLUK FONKSIYONLARI BULUNMASI
% VE GORUNTU SINIFLANDIRMASI
% BU KOD EMRE MOLA TARAFINDAN YAZILMISTIR
% ANADOLU UNIVERSITESI FEN BILIMLERI ENSTITUSU
% UZAKTAN ALGILAMA VE COGRAFI BILGI SISTEMLERI
% DOKTORA TEZI ICIN GELISTIRILMISTIR
clear all, close all, clc
format long
k=input('Uydu Goruntusundeki Tahmini Kume Sayisini Giriniz=');
x=imread('C:\Users\EMRE\Desktop\DOKTORA
TEZI\DATA\landsat_8_eskisehir743s4.tif');
dlmwrite('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_15s\ASCII\3b15s1.txt',(x(:,:,1)),'precision',
%.6f)
subplot(4,4,1)
hold on
y1=imshow((x(:,:,1)));
hold off
```

```

load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_15s\ASCII\3b15s1.txt');
v1=load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_15s\ASCII\3b15s1.txt');
d1mwrite('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_15s\ASCII\3b15s2.txt',(x(:,:,2)), 'precision',
%.6f)
subplot(4,4,2)
hold on
y2=imshow((x(:,:,2)));
hold off
load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_15s\ASCII\3b15s2.txt');
v2=load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_15s\ASCII\3b15s2.txt');
d2mwrite('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_15s\ASCII\3b15s3.txt',(x(:,:,3)), 'precision',
%.6f)
subplot(4,4,3)
hold on
y3=imshow((x(:,:,3)));
hold off
load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_15s\ASCII\3b15s3.txt');
v3=load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_15s\ASCII\3b15s3.txt');
D1=(reshape(v1,263440,1));
D2=(reshape(v2,263440,1));
D3=(reshape(v3,263440,1));
(x(:,:,1));
(x(:,:,2));
(x(:,:,3));
D1;
D2;
D3;
D=[D1 D2 D3]
options = statset('MaxIter',500)
obj = gmdistribution.fit([D1 D2 D3],k,'Options',options,'Regularize',1e-
50);
ComponentCovariances = obj.Sigma
MixtureProportions = obj.PComponents
MixtureMeans =obj.mu
D=[D1 D2 D3]
%
% MODIFIYE EM ALGORITMASI ILE BULUNAN
% KARMA MODEL YARDIMI ILE
% HER BIR PİKSEL İÇİN
% OLASILIK KARSILASTIRMALARI
%
%
%
%
P1=obj.PComponents(1)*mvnpdf([D],obj.mu(1,:,:),(obj.Sigma(:,:,1)));
P2=obj.PComponents(2)*mvnpdf([D],obj.mu(2,:,:),(obj.Sigma(:,:,2)));
P3=obj.PComponents(3)*mvnpdf([D],obj.mu(3,:,:),(obj.Sigma(:,:,3)));
P4=obj.PComponents(4)*mvnpdf([D],obj.mu(4,:,:),(obj.Sigma(:,:,4)));
P5=obj.PComponents(5)*mvnpdf([D],obj.mu(5,:,:),(obj.Sigma(:,:,5)));
P6=obj.PComponents(6)*mvnpdf([D],obj.mu(6,:,:),(obj.Sigma(:,:,6)));
P7=obj.PComponents(7)*mvnpdf([D],obj.mu(7,:,:),(obj.Sigma(:,:,7)));

```

```

P8=obj.PComponents(8)*mvnpdf([D],obj.mu(8,:,:),(obj.Sigma(:, :,8)));
P9=obj.PComponents(9)*mvnpdf([D],obj.mu(9,:,:),(obj.Sigma(:, :,9)));

P10=obj.PComponents(10)*mvnpdf([D],obj.mu(10,:,:),(obj.Sigma(:, :,10)))
;

P11=obj.PComponents(11)*mvnpdf([D],obj.mu(11,:,:),(obj.Sigma(:, :,11)))
;

P12=obj.PComponents(12)*mvnpdf([D],obj.mu(12,:,:),(obj.Sigma(:, :,12)))
;

P13=obj.PComponents(13)*mvnpdf([D],obj.mu(13,:,:),(obj.Sigma(:, :,13)))
;

P14=obj.PComponents(14)*mvnpdf([D],obj.mu(14,:,:),(obj.Sigma(:, :,14)))
;

P15=obj.PComponents(15)*mvnpdf([D],obj.mu(15,:,:),(obj.Sigma(:, :,15)))
;
    for p=1:1:length(D);
        p
        if
            (P1(p)>P2(p))&&(P1(p)>P3(p))&&(P1(p)>P4(p))&&(P1(p)>P5(p))&&(P
            1(p)>P6(p))&&(P1(p)>P7(p))&&(P1(p)>P8(p))&&(P1(p)>P9(p))&&(P1(
            p)>P10(p))&&(P1(p)>P11(p))&&(P1(p)>P12(p))&&(P1(p)>P13(p))&&(P
            1(p)>P14(p))&&(P1(p)>P15(p))
                c=1
            elseif
                (P2(p)>P1(p))&&(P2(p)>P3(p))&&(P2(p)>P4(p))&&(P2(p)>P5(p))&&(P
                2(p)>P6(p))&&(P2(p)>P7(p))&&(P2(p)>P8(p))&&(P2(p)>P9(p))&&(P2(
                p)>P10(p))&&(P2(p)>P11(p))&&(P2(p)>P12(p))&&(P2(p)>P13(p))&&(P
                2(p)>P14(p))&&(P2(p)>P15(p))
                    c=2
                elseif
                    (P3(p)>P1(p))&&(P3(p)>P2(p))&&(P3(p)>P4(p))&&(P3(p)>P5(p))&&(P
                    3(p)>P6(p))&&(P3(p)>P7(p))&&(P3(p)>P8(p))&&(P3(p)>P9(p))&&(P3(
                    p)>P10(p))&&(P3(p)>P11(p))&&(P3(p)>P12(p))&&(P3(p)>P13(p))&&(P
                    3(p)>P14(p))&&(P3(p)>P15(p))
                        c=3
                    elseif
                        (P4(p)>P1(p))&&(P4(p)>P2(p))&&(P4(p)>P3(p))&&(P4(p)>P5(p))&&(P
                        4(p)>P6(p))&&(P4(p)>P7(p))&&(P4(p)>P8(p))&&(P4(p)>P9(p))&&(P4(
                        p)>P10(p))&&(P4(p)>P11(p))&&(P4(p)>P12(p))&&(P4(p)>P13(p))&&(P
                        4(p)>P14(p))&&(P4(p)>P15(p))
                            c=4
                        elseif
                            (P5(p)>P1(p))&&(P5(p)>P2(p))&&(P5(p)>P3(p))&&(P5(p)>P4(p))&&(P
                            5(p)>P6(p))&&(P5(p)>P7(p))&&(P5(p)>P8(p))&&(P5(p)>P9(p))&&(P5(
                            p)>P10(p))&&(P5(p)>P11(p))&&(P5(p)>P12(p))&&(P5(p)>P13(p))&&(P
                            5(p)>P14(p))&&(P5(p)>P15(p))
                                c=5
                            elseif
                                (P6(p)>P1(p))&&(P6(p)>P2(p))&&(P6(p)>P3(p))&&(P6(p)>P4(p))&&(P
                                6(p)>P5(p))&&(P6(p)>P7(p))&&(P6(p)>P8(p))&&(P6(p)>P9(p))&&(P6(
                                p)>P10(p))&&(P6(p)>P11(p))&&(P6(p)>P12(p))&&(P6(p)>P13(p))&&(P
                                6(p)>P14(p))&&(P6(p)>P15(p))
                                    c=6
                                else

```

```

elseif
(P7(p)>P1(p))&&(P7(p)>P2(p))&&(P7(p)>P3(p))&&(P7(p)>P4(p))&&(P
7(p)>P5(p))&&(P7(p)>P6(p))&&(P7(p)>P8(p))&&(P7(p)>P9(p))&&(P7(
p)>P10(p))&&(P7(p)>P11(p))&&(P7(p)>P12(p))&&(P7(p)>P13(p))&&(P
7(p)>P14(p))&&(P7(p)>P15(p))
c=7
elseif
(P8(p)>P1(p))&&(P8(p)>P2(p))&&(P8(p)>P3(p))&&(P8(p)>P4(p))&&(P
8(p)>P5(p))&&(P8(p)>P6(p))&&(P8(p)>P7(p))&&(P8(p)>P9(p))&&(P8(
p)>P10(p))&&(P8(p)>P11(p))&&(P8(p)>P12(p))&&(P8(p)>P13(p))&&(P
8(p)>P14(p))&&(P8(p)>P15(p))
c=8
elseif
(P9(p)>P1(p))&&(P9(p)>P2(p))&&(P9(p)>P3(p))&&(P9(p)>P4(p))&&(P
9(p)>P5(p))&&(P9(p)>P6(p))&&(P9(p)>P7(p))&&(P9(p)>P8(p))&&(P9(
p)>P10(p))&&(P9(p)>P11(p))&&(P9(p)>P12(p))&&(P9(p)>P13(p))&&(P
9(p)>P14(p))&&(P9(p)>P15(p))
c=9
elseif
(P10(p)>P1(p))&&(P10(p)>P2(p))&&(P10(p)>P3(p))&&(P10(p)>P4(p))&
&(P10(p)>P5(p))&&(P10(p)>P6(p))&&(P10(p)>P7(p))&&(P10(p)>P8(p))
&&(P10(p)>P9(p))&&(P10(p)>P11(p))&&(P10(p)>P12(p))&&(P10(p)>P
13(p))&&(P10(p)>P14(p))&&(P10(p)>P15(p))
c=10
elseif
(P11(p)>P1(p))&&(P11(p)>P2(p))&&(P11(p)>P3(p))&&(P11(p)>P4(p))&
&(P11(p)>P5(p))&&(P11(p)>P6(p))&&(P11(p)>P7(p))&&(P11(p)>P8(p))
&&(P11(p)>P9(p))&&(P11(p)>P10(p))&&(P11(p)>P12(p))&&(P11(p)>P
13(p))&&(P11(p)>P14(p))&&(P11(p)>P15(p))
c=11
elseif
(P12(p)>P1(p))&&(P12(p)>P2(p))&&(P12(p)>P3(p))&&(P12(p)>P4(p))&
&(P12(p)>P5(p))&&(P12(p)>P6(p))&&(P12(p)>P7(p))&&(P12(p)>P8(p))
&&(P12(p)>P9(p))&&(P12(p)>P10(p))&&(P12(p)>P11(p))&&(P12(p)>P
13(p))&&(P12(p)>P14(p))&&(P12(p)>P15(p))
c=12
elseif
(P13(p)>P1(p))&&(P13(p)>P2(p))&&(P13(p)>P3(p))&&(P13(p)>P4(p))&
&(P13(p)>P5(p))&&(P13(p)>P6(p))&&(P13(p)>P7(p))&&(P13(p)>P8(p))
&&(P13(p)>P9(p))&&(P13(p)>P10(p))&&(P13(p)>P11(p))&&(P13(p)>P
12(p))&&(P13(p)>P14(p))&&(P13(p)>P15(p))
c=13
elseif
(P14(p)>P1(p))&&(P14(p)>P2(p))&&(P14(p)>P3(p))&&(P14(p)>P4(p))&
&(P14(p)>P5(p))&&(P14(p)>P6(p))&&(P14(p)>P7(p))&&(P14(p)>P8(p))
&&(P14(p)>P9(p))&&(P14(p)>P10(p))&&(P14(p)>P11(p))&&(P14(p)>P
12(p))&&(P14(p)>P13(p))&&(P14(p)>P15(p))
c=14
else
(P15(p)>P1(p))&&(P15(p)>P2(p))&&(P15(p)>P3(p))&&(P15(p)>P4(p))&
&(P15(p)>P5(p))&&(P15(p)>P6(p))&&(P15(p)>P7(p))&&(P15(p)>P8(p))
&&(P15(p)>P9(p))&&(P15(p)>P10(p))&&(P15(p)>P11(p))&&(P15(p)>P
12(p))&&(P15(p)>P13(p))&&(P15(p)>P14(p));
c=15
end
if
(P1(p)>P2(p))&&(P1(p)>P3(p))&&(P1(p)>P4(p))&&(P1(p)>P5(p))&&(P
1(p)>P6(p))&&(P1(p)>P7(p))&&(P1(p)>P8(p))&&(P1(p)>P9(p))&&(P1(

```

```

p>P10(p))&&(P1(p)>P11(p))&&(P1(p)>P12(p))&&(P1(p)>P13(p))&&(P
1(p)>P14(p))&&(P1(p)>P15(p))
    c=1; s=17; d= fprintf("%d\n",s);
elseif
(P2(p)>P1(p))&&(P2(p)>P3(p))&&(P2(p)>P4(p))&&(P2(p)>P5(p))&&(P
2(p)>P6(p))&&(P2(p)>P7(p))&&(P2(p)>P8(p))&&(P2(p)>P9(p))&&(P2(
p)>P10(p))&&(P2(p)>P11(p))&&(P2(p)>P12(p))&&(P2(p)>P13(p))&&(P
2(p)>P14(p))&&(P2(p)>P15(p))
    c=2; s=34; d= fprintf("%d\n",s);
elseif
(P3(p)>P1(p))&&(P3(p)>P2(p))&&(P3(p)>P4(p))&&(P3(p)>P5(p))&&(P
3(p)>P6(p))&&(P3(p)>P7(p))&&(P3(p)>P8(p))&&(P3(p)>P9(p))&&(P3(
p)>P10(p))&&(P3(p)>P11(p))&&(P3(p)>P12(p))&&(P3(p)>P13(p))&&(P
3(p)>P14(p))&&(P3(p)>P15(p))
    c=3; s=51; d= fprintf("%d\n",s);
elseif
(P4(p)>P1(p))&&(P4(p)>P2(p))&&(P4(p)>P3(p))&&(P4(p)>P5(p))&&(P
4(p)>P6(p))&&(P4(p)>P7(p))&&(P4(p)>P8(p))&&(P4(p)>P9(p))&&(P4(
p)>P10(p))&&(P4(p)>P11(p))&&(P4(p)>P12(p))&&(P4(p)>P13(p))&&(P
4(p)>P14(p))&&(P4(p)>P15(p))
    c=4; s=68; d= fprintf("%d\n",s);
elseif
(P5(p)>P1(p))&&(P5(p)>P2(p))&&(P5(p)>P3(p))&&(P5(p)>P4(p))&&(P
5(p)>P6(p))&&(P5(p)>P7(p))&&(P5(p)>P8(p))&&(P5(p)>P9(p))&&(P5(
p)>P10(p))&&(P5(p)>P11(p))&&(P5(p)>P12(p))&&(P5(p)>P13(p))&&(P
5(p)>P14(p))&&(P5(p)>P15(p))
    c=5; s=85; d= fprintf("%d\n",s);
elseif
(P6(p)>P1(p))&&(P6(p)>P2(p))&&(P6(p)>P3(p))&&(P6(p)>P4(p))&&(P
6(p)>P5(p))&&(P6(p)>P7(p))&&(P6(p)>P8(p))&&(P6(p)>P9(p))&&(P6(
p)>P10(p))&&(P6(p)>P11(p))&&(P6(p)>P12(p))&&(P6(p)>P13(p))&&(P
6(p)>P14(p))&&(P6(p)>P15(p))
    c=6; s=102; d= fprintf("%d\n",s);
elseif
(P7(p)>P1(p))&&(P7(p)>P2(p))&&(P7(p)>P3(p))&&(P7(p)>P4(p))&&(P
7(p)>P5(p))&&(P7(p)>P6(p))&&(P7(p)>P8(p))&&(P7(p)>P9(p))&&(P7(
p)>P10(p))&&(P7(p)>P11(p))&&(P7(p)>P12(p))&&(P7(p)>P13(p))&&(P
7(p)>P14(p))&&(P7(p)>P15(p))
    c=7; s=119; d= fprintf("%d\n",s);
elseif
(P8(p)>P1(p))&&(P8(p)>P2(p))&&(P8(p)>P3(p))&&(P8(p)>P4(p))&&(P
8(p)>P5(p))&&(P8(p)>P6(p))&&(P8(p)>P7(p))&&(P8(p)>P9(p))&&(P8(
p)>P10(p))&&(P8(p)>P11(p))&&(P8(p)>P12(p))&&(P8(p)>P13(p))&&(P
8(p)>P14(p))&&(P8(p)>P15(p))
    c=8; s=136; d= fprintf("%d\n",s);
elseif
(P9(p)>P1(p))&&(P9(p)>P2(p))&&(P9(p)>P3(p))&&(P9(p)>P4(p))&&(P
9(p)>P5(p))&&(P9(p)>P6(p))&&(P9(p)>P7(p))&&(P9(p)>P8(p))&&(P9(
p)>P10(p))&&(P9(p)>P11(p))&&(P9(p)>P12(p))&&(P9(p)>P13(p))&&(P
9(p)>P14(p))&&(P9(p)>P15(p))
    c=9; s=153; d= fprintf("%d\n",s);
elseif
(P10(p)>P1(p))&&(P10(p)>P2(p))&&(P10(p)>P3(p))&&(P10(p)>P4(p))&
&(P10(p)>P5(p))&&(P10(p)>P6(p))&&(P10(p)>P7(p))&&(P10(p)>P8(p))
&&(P10(p)>P9(p))&&(P10(p)>P11(p))&&(P10(p)>P12(p))&&(P10(p)>P
13(p))&&(P10(p)>P14(p))&&(P10(p)>P15(p))
    c=10; s=170; d= fprintf("%d\n",s);
elseif
(P11(p)>P1(p))&&(P11(p)>P2(p))&&(P11(p)>P3(p))&&(P11(p)>P4(p))&

```

```


&(P11(p)>P5(p))&&(P11(p)>P6(p))&&(P11(p)>P7(p))&&(P11(p)>P8(p))
&&(P11(p)>P9(p))&&(P11(p)>P10(p))&&(P11(p)>P12(p))&&(P11(p)>P
13(p))&&(P11(p)>P14(p))&&(P11(p)>P15(p))
    c=11; s=187; d= fprintf('%d\n',s);
    elseif
(P12(p)>P1(p))&&(P12(p)>P2(p))&&(P12(p)>P3(p))&&(P12(p)>P4(p))&
&(P12(p)>P5(p))&&(P12(p)>P6(p))&&(P12(p)>P7(p))&&(P12(p)>P8(p))
&&(P12(p)>P9(p))&&(P12(p)>P10(p))&&(P12(p)>P11(p))&&(P12(p)>P
13(p))&&(P12(p)>P14(p))&&(P12(p)>P15(p))
    c=12; s=204; d= fprintf('%d\n',s);
    elseif
(P13(p)>P1(p))&&(P13(p)>P2(p))&&(P13(p)>P3(p))&&(P13(p)>P4(p))&
&(P13(p)>P5(p))&&(P13(p)>P6(p))&&(P13(p)>P7(p))&&(P13(p)>P8(p))
&&(P13(p)>P9(p))&&(P13(p)>P10(p))&&(P13(p)>P11(p))&&(P13(p)>P
12(p))&&(P13(p)>P14(p))&&(P13(p)>P15(p))
    c=13; s=221; d= fprintf('%d\n',s);
    elseif
(P14(p)>P1(p))&&(P14(p)>P2(p))&&(P14(p)>P3(p))&&(P14(p)>P4(p))&
&(P14(p)>P5(p))&&(P14(p)>P6(p))&&(P14(p)>P7(p))&&(P14(p)>P8(p))
&&(P14(p)>P9(p))&&(P14(p)>P10(p))&&(P14(p)>P11(p))&&(P14(p)>P
12(p))&&(P14(p)>P13(p))&&(P14(p)>P15(p))
    c=14; s=238; d= fprintf('%d\n',s);
    else
(P15(p)>P1(p))&&(P15(p)>P2(p))&&(P15(p)>P3(p))&&(P15(p)>P4(p))&
&(P15(p)>P5(p))&&(P15(p)>P6(p))&&(P15(p)>P7(p))&&(P15(p)>P8(p))
&&(P15(p)>P9(p))&&(P15(p)>P10(p))&&(P15(p)>P11(p))&&(P15(p)>P
12(p))&&(P15(p)>P13(p))&&(P15(p)>P14(p))
    c=15; s=255; d= fprintf('%d\n',s);
    end
    fileID=fopen('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_15s\SINIF RENK\3b15s.txt','a+');
    fprintf(fileID, '%3.8f\n',s);
    fclose(fileID);
end
load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_15s\SINIF RENK\3b15s.txt');
z=load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_15s\SINIF RENK\3b15s.txt');
E(:,:,1)=(reshape(z,445,592));
subplot(4,4,4)
hold on
imshow(E(:,:,1),colormap(prism(275)))
hold off
imwrite(E(:,:,1),'C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\EskLandsat8_3b_15s\GORUNTU\3b15s.jpeg');
imwrite(E(:,:,1),colormap(prism(250)), 'C:\Users\EMRE\Desktop\DOKTO
RA TEZI\Veriler\EskLandsat8_3b_15s\GORUNTU\3b15s.tif');
subplot(4,4,5)
hold on
imshow(E(:,:,1),colormap(prism(250)))
hold off

```

4.2.8. Modifiye EM Algoritmasının Satürn Gezegeni Etrafındaki Halkalara Ait Uzaktan Algılama Verisine Uygulanması

Satürn gezegeninin halka sisteminin bir kısmındaki olası kimyasal bileşimlerinden diğerine özel bilgisayar işleme teknikleri ile ince renk değişimleri olarak Şekil 4.23 Voyager-2 verisi tarafından elde edilmiştir. (Anonim, 1981).

Satürn halkalarına ait uzaktan algılama verisinin tahmini sınıfı 20 olarak belirlenmiştir. Bu veriye ait toplam piksel sayısı 940.986'dır. Bu uzaktan algılama verisinde tekillik sorunu nedeni ile modifiye edilmiştir.



Şekil 4.23. Voyager-2'den elde edilmiş Satürn gezegeninin halkaları uzaktan algılama verisi (Anonim, 1981)

Algoritma (2.3) kullanılarak, EM algoritması yardımı ile sınıflandırması yapılacak üç bantlı ve tahmini olarak 20 bileşenli yani 20 sınıflı Şekil 4.23'deki alan için modifiye EM algoritması yardımı ile yapılan karma modele ait her bileşenin olasılık yoğunluk fonksiyonlarının bulunmasını sağlayarak bu sayede sınıflandırma yapan ve sonucu sınıflandırılmış görüntü olarak veren geliştirilmiş matlab kodu yer almaktadır:

```

% SATURN GEZEGENI HALKALARI ICIN
% MODIFIYE EM ALGORITMASI YARDIMIYLA PARAMETRE
% TAHMINI VE
% KARMA OLASILIK YOGUNLUK FONKSIYONLARI BULUNMASI
% VE GORUNTU SINIFLANDIRMASI
% BU KOD EMRE MOLA TARAFINDAN YAZILMISTIR
% ANADOLU UNIVERSITESI FEN BILIMLERI ENSTITUSU
% UZAKTAN ALGILAMA VE COGRAFI BILGI SISTEMLERI
% DOKTORA TEZI ICIN GELISTIRILMISTIR
clear all, close all, clc
format long
k=input('Uydu Goruntusundeki Tahmini Kume Sayisini Giriniz=');
x=imread('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\Saturn\PIA01486.tif');
dlmwrite('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\Saturn\ASCII\Saturn1.txt',(x(:,1)), 'precision', '%.6f')
subplot(4,4,1)
hold on
y1=imshow((x(:,1)));
hold off
load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\Saturn\ASCII\Saturn1.txt');
v1=load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\Saturn\ASCII\Saturn1.txt');
dlmwrite('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\Saturn\ASCII\Saturn2.txt',(x(:,2)), 'precision', '%.6f')
subplot(4,4,2)
hold on
y2=imshow((x(:,2)));
hold off
load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\Saturn\ASCII\Saturn2.txt');
v2=load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\Saturn\ASCII\Saturn2.txt');
dlmwrite('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\Saturn\ASCII\Saturn3.txt',(x(:,3)), 'precision', '%.6f')
subplot(4,4,3)
hold on
y3=imshow((x(:,3)));
hold off
load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\Saturn\ASCII\Saturn3.txt');
v3=load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\Saturn\ASCII\Saturn3.txt');
D1=(reshape(v1,940986,1));
D2=(reshape(v2,940986,1));
D3=(reshape(v3,940986,1));
(x(:,1));
(x(:,2));
(x(:,3));
D1;
D2;
D3;
options = statset('MaxIter',500)
obj = gmdistribution.fit([D1 D2 D3],k,'Options',options,'Regularize',1e-5);
ComponentCovariances = obj.Sigma
MixtureProportions = obj.PComponents
MixtureMeans =obj.mu
D=[D1 D2 D3]

```

```

%
% MODIFIYE EM ALGORITMASI ILE BULUNAN
% KARMA MODEL YARDIMI ILE
% HER BIR PİKSEL İÇİN
% OLASILIK KARSILASTIRMALARI
%
%
%
%
%
P1=obj.PComponents(1)*mvnpdf([D],obj.mu(1,:::),(obj.Sigma(:,,1)));
P2=obj.PComponents(2)*mvnpdf([D],obj.mu(2,:::),(obj.Sigma(:,,2)));
P3=obj.PComponents(3)*mvnpdf([D],obj.mu(3,:::),(obj.Sigma(:,,3)));
P4=obj.PComponents(4)*mvnpdf([D],obj.mu(4,:::),(obj.Sigma(:,,4)));
P5=obj.PComponents(5)*mvnpdf([D],obj.mu(5,:::),(obj.Sigma(:,,5)));
P6=obj.PComponents(6)*mvnpdf([D],obj.mu(6,:::),(obj.Sigma(:,,6)));
P7=obj.PComponents(7)*mvnpdf([D],obj.mu(7,:::),(obj.Sigma(:,,7)));
P8=obj.PComponents(8)*mvnpdf([D],obj.mu(8,:::),(obj.Sigma(:,,8)));
P9=obj.PComponents(9)*mvnpdf([D],obj.mu(9,:::),(obj.Sigma(:,,9)));
P10=obj.PComponents(10)*mvnpdf([D],obj.mu(10,:::),(obj.Sigma(:,,10)));
P11=obj.PComponents(11)*mvnpdf([D],obj.mu(11,:::),(obj.Sigma(:,,11)));
P12=obj.PComponents(12)*mvnpdf([D],obj.mu(12,:::),(obj.Sigma(:,,12)));
P13=obj.PComponents(13)*mvnpdf([D],obj.mu(13,:::),(obj.Sigma(:,,13)));
P14=obj.PComponents(14)*mvnpdf([D],obj.mu(14,:::),(obj.Sigma(:,,14)));
P15=obj.PComponents(15)*mvnpdf([D],obj.mu(15,:::),(obj.Sigma(:,,15)));
P16=obj.PComponents(16)*mvnpdf([D],obj.mu(16,:::),(obj.Sigma(:,,16)));
P17=obj.PComponents(17)*mvnpdf([D],obj.mu(17,:::),(obj.Sigma(:,,17)));
P18=obj.PComponents(18)*mvnpdf([D],obj.mu(18,:::),(obj.Sigma(:,,18)));
P19=obj.PComponents(19)*mvnpdf([D],obj.mu(19,:::),(obj.Sigma(:,,19)));
P20=obj.PComponents(20)*mvnpdf([D],obj.mu(20,:::),(obj.Sigma(:,,20)));
    for p=1:1:length(D);
        p
        if
            (P1(p)>P2(p))&&(P1(p)>P3(p))&&(P1(p)>P4(p))&&(P1(p)>P5(p))&&(P1(
                p)>P6(p))&&(P1(p)>P7(p))&&(P1(p)>P8(p))&&(P1(p)>P9(p))&&(P1(p)>
                P10(p))&&(P1(p)>P11(p))&&(P1(p)>P12(p))&&(P1(p)>P13(p))&&(P1(p)
                >P14(p))&&(P1(p)>P15(p))&&(P1(p)>P16(p))&&(P1(p)>P17(p))&&(P1(p)
                >P18(p))&&(P1(p)>P19(p))&&(P1(p)>P20(p))
                c=1
            elseif
                (P2(p)>P1(p))&&(P2(p)>P3(p))&&(P2(p)>P4(p))&&(P2(p)>P5(p))&&(P2(
                    p)>P6(p))&&(P2(p)>P7(p))&&(P2(p)>P8(p))&&(P2(p)>P9(p))&&(P2(p)>
                    P10(p))&&(P2(p)>P11(p))&&(P2(p)>P12(p))&&(P2(p)>P13(p))&&(P2(p)
                    >P14(p))&&(P2(p)>P15(p))&&(P2(p)>P16(p))&&(P2(p)>P17(p))&&(P2(p)
                    >P18(p))&&(P2(p)>P19(p))&&(P2(p)>P20(p))
                    c=2
                elseif
                    (P3(p)>P1(p))&&(P3(p)>P2(p))&&(P3(p)>P4(p))&&(P3(p)>P5(p))&&(P3(
                        p)>P6(p))&&(P3(p)>P7(p))&&(P3(p)>P8(p))&&(P3(p)>P9(p))&&(P3(p)>
                        P10(p))&&(P3(p)>P11(p))&&(P3(p)>P12(p))&&(P3(p)>P13(p))&&(P3(p)
                        >P14(p))&&(P3(p)>P15(p))&&(P3(p)>P16(p))&&(P3(p)>P17(p))&&(P3(p)
                        >P18(p))&&(P3(p)>P19(p))&&(P3(p)>P20(p))
                            c=3
                    elseif
                        (P4(p)>P1(p))&&(P4(p)>P2(p))&&(P4(p)>P3(p))&&(P4(p)>P5(p))&&(P4(
                            p)>P6(p))&&(P4(p)>P7(p))&&(P4(p)>P8(p))&&(P4(p)>P9(p))&&(P4(p)>
                            P10(p))&&(P4(p)>P11(p))&&(P4(p)>P12(p))&&(P4(p)>P13(p))&&(P4(p)
                            >P14(p))&&(P4(p)>P15(p))&&(P4(p)>P16(p))&&(P4(p)>P17(p))&&(P4(p)
                            >P18(p))&&(P4(p)>P19(p))&&(P4(p)>P20(p))
                                c=4
                    end
                end
            end
        end
    end

```



```

&&(P18(p)>P9(p))&&(P18(p)>P10(p))&&(P18(p)>P11(p))&&(P18(p)>P1
2(p))&&(P18(p)>P13(p))&&(P18(p)>P14(p))&&(P18(p)>P15(p))&&(P18(
p)>P16(p))&&(P18(p)>P17(p))&&(P18(p)>P19(p))&&(P18(p)>P20(p))
    c=18; s=234; d= fprintf('%d\n',s);
elseif
(P19(p)>P1(p))&&(P19(p)>P2(p))&&(P19(p)>P3(p))&&(P19(p)>P4(p))&
&(P19(p)>P5(p))&&(P19(p)>P6(p))&&(P19(p)>P7(p))&&(P19(p)>P8(p))
&&(P19(p)>P9(p))&&(P19(p)>P10(p))&&(P19(p)>P11(p))&&(P19(p)>P1
2(p))&&(P19(p)>P13(p))&&(P19(p)>P14(p))&&(P19(p)>P15(p))&&(P19(
p)>P16(p))&&(P19(p)>P17(p))&&(P19(p)>P18(p))&&(P19(p)>P20(p))
    c=19; s=247; d= fprintf('%d\n',s);
else
(P20(p)>P1(p))&&(P20(p)>P2(p))&&(P20(p)>P3(p))&&(P20(p)>P4(p))&
&(P20(p)>P5(p))&&(P20(p)>P6(p))&&(P20(p)>P7(p))&&(P20(p)>P8(p))
&&(P20(p)>P9(p))&&(P20(p)>P10(p))&&(P20(p)>P11(p))&&(P20(p)>P1
2(p))&&(P20(p)>P13(p))&&(P20(p)>P14(p))&&(P20(p)>P15(p))&&(P20(
p)>P16(p))&&(P20(p)>P17(p))&&(P20(p)>P18(p))&&(P20(p)>P19(p))
    c=20; s=255; d= fprintf('%d\n',s);
end
fileID = fopen('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\Saturn\SINIF RENK\Saturn.txt','a+');
fprintf(fileID, '%3.8f\n',s);
fclose(fileID);
end
load('C:\Users\EMRE\Desktop\DOKTORA TEZI\Veriler\Saturn\SINIF
RENK\Saturn.txt');
z=load('C:\Users\EMRE\Desktop\DOKTORA TEZI\Veriler\Saturn\SINIF
RENK\Saturn.txt');
E(:,1)=(reshape(z,857,1098));
subplot(4,4,4)
hold on
imshow(E(:,1),colormap(prism(275)))
hold off
imwrite(E(:,1),'C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\Saturn\GORUNTU\EMSaturn.tif');
imwrite(E(:,1),colormap(prism(250)), 'C:\Users\EMRE\Desktop\DOKTOR
A TEZI\Veriler\Saturn\GORUNTU\Saturn.jpeg');
subplot(4,4,5)
hold on
imshow(E(:,1),colormap(prism(250)))
hold off

```

4.2.9. EM Algoritmasının Jüpiter Gezegeni Atmosferi Uzaktan Algılama Verisine Uygulanması


Bu uygulamada NASA'nın sayfasından elde edilen Jüpiterin büyük kırmızı beneği isimli uzaktan algılama verisine EM algoritması uygulanacaktır.

Şekil (4.24)'de Jupiter gezegeni gözükmektedir (Anonim 2011). Şekil (4.25)'deki uzaktan algılama verisine ait görüntü Voyager-1 tarafından çekilmiştir (Anonim, 1998). Bu görüntüde Jüpiter gezegeninin atmosferi daha büyük ve ayrıntılı olarak gözükmektedir. Jupiter gezegeni ve kırmızı kahve rengi tonunda

büyük benek olarak isimlendirilen ve aslında Jüpiter gezegenindeki fırtına olan uzaktan algılama verisi daha net olarak gözükmektedir.




Şekil 4.24. Jüpiter gezegeni (Anonim, 2011)



Şekil 4.25. Jüpiter'in büyük kırmızı beneği (Anonim,1998)

Şekil (4.26)'da ise sınıflandırması yapılacak Jüpiter gezegeninin atmosferine ait alan mevcuttur:



Şekil 4.26. Jüpiter'in büyük kırmızı beneği verisinden EM algoritmasına uygulanacak olan kısım
(Anonim,1998)

Aşağıda üç bantlı ve tahmini olarak 20 bileşenli yani 20 sınıflı Şekil 4.26'daki alan için EM algoritması yardımı ile yapılan karma modele ait her bileşenin olasılık yoğunluk fonksiyonlarının bulunmasını sağlayarak bu sayede sınıflandırma yapan ve sonucu sınıflandırılmış görüntü olarak veren geliştirilmiş modifiyesiz matlab kodu yer almaktadır:

```
% JUPITER GEZEGENI ATMOSFERIK VERISI ICIN
% EM ALGORITMASI YARDIMIYLA PARAMETRE TAHMINI VE
% KARMA OLASILIK YOGUNLUK FONKSIYONLARI BULUNMASI
% VE GORUNTU SINIFLANDIRMASI
% BU KOD EMRE MOLA TARAFINDAN YAZILMISTIR
% ANADOLU UNIVERSITESI FEN BILIMLERI ENSTITUSU
% UZAKTAN ALGILAMA VE COGRAFI BILGI SISTEMLERI
% DOKTORA TEZI ICIN GELISTIRILMISTIR
clear all, close all, clc
format long
k=input('Uydu Goruntusundeki Tahmini Kume Sayisini Giriniz=');
x=imread('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\Jupiter\jupiter01384b.tif');
dlmwrite('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\Jupiter\ASCII\jupiter1.txt',(x(:,:,1)),'precision','% .6f')
subplot(4,4,1)
hold on
y1=imshow((x(:,:,1)));
hold off
load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\Jupiter\ASCII\jupiter1.txt');
```

```

v1=load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\Jupiter\ASCII\jupiter1.txt');
dlmwrite('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\Jupiter\ASCII\jupiter2.txt',(x(:, :, 2)), 'precision', '%.6f')
subplot(4,4,2)
hold on
y2=imshow((x(:, :, 2)));
hold off
load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\Jupiter\ASCII\jupiter2.txt');
v2=load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\Jupiter\ASCII\jupiter2.txt');
dlmwrite('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\Jupiter\ASCII\jupiter3.txt',(x(:, :, 3)), 'precision', '%.6f')
subplot(4,4,3)
hold on
y3=imshow((x(:, :, 3)));
hold off
load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\Jupiter\ASCII\jupiter3.txt');
v3=load('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\Jupiter\ASCII\jupiter3.txt');
D1=(reshape(v1,3086075,1));
D2=(reshape(v2,3086075,1));
D3=(reshape(v3,3086075,1));
(x(:, :, 1));
(x(:, :, 2));
(x(:, :, 3));
D1;
D2;
D3;
% options = statset('MaxIter',500)
obj = gmdistribution.fit([D1 D2 D3],k)
% obj = gmdistribution.fit([D1 D2 D3],k,'Options',options,'Regularize',1e-
50);
ComponentCovariances = obj.Sigma
MixtureProportions = obj.PComponents
MixtureMeans =obj.mu
D=[D1 D2 D3]
%
% EM ALGORITMASI ILE BULUNAN
% KARMA MODEL YARDIMI ILE
% HER BIR PİKSEL İCİN
% OLASILIK KARSILASTIRMALARI
%
%
%
%
P1=obj.PComponents(1)*mvnpdf([D],obj.mu(1, :, :),(obj.Sigma(:, :, 1)));
P2=obj.PComponents(2)*mvnpdf([D],obj.mu(2, :, :),(obj.Sigma(:, :, 2)));
P3=obj.PComponents(3)*mvnpdf([D],obj.mu(3, :, :),(obj.Sigma(:, :, 3)));
P4=obj.PComponents(4)*mvnpdf([D],obj.mu(4, :, :),(obj.Sigma(:, :, 4)));
P5=obj.PComponents(5)*mvnpdf([D],obj.mu(5, :, :),(obj.Sigma(:, :, 5)));
P6=obj.PComponents(6)*mvnpdf([D],obj.mu(6, :, :),(obj.Sigma(:, :, 6)));
P7=obj.PComponents(7)*mvnpdf([D],obj.mu(7, :, :),(obj.Sigma(:, :, 7)));
P8=obj.PComponents(8)*mvnpdf([D],obj.mu(8, :, :),(obj.Sigma(:, :, 8)));
P9=obj.PComponents(9)*mvnpdf([D],obj.mu(9, :, :),(obj.Sigma(:, :, 9)));
P10=obj.PComponents(10)*mvnpdf([D],obj.mu(10, :, :),(obj.Sigma(:, :, 10)));
P11=obj.PComponents(11)*mvnpdf([D],obj.mu(11, :, :),(obj.Sigma(:, :, 11)));

```

```

P12=obj.PComponents(12)*mvnpdf([D],obj.mu(12,:,:),(obj.Sigma(:,:,12)));
P13=obj.PComponents(13)*mvnpdf([D],obj.mu(13,:,:),(obj.Sigma(:,:,13)));
P14=obj.PComponents(14)*mvnpdf([D],obj.mu(14,:,:),(obj.Sigma(:,:,14)));
P15=obj.PComponents(15)*mvnpdf([D],obj.mu(15,:,:),(obj.Sigma(:,:,15)));
P16=obj.PComponents(16)*mvnpdf([D],obj.mu(16,:,:),(obj.Sigma(:,:,16)));
P17=obj.PComponents(17)*mvnpdf([D],obj.mu(17,:,:),(obj.Sigma(:,:,17)));
P18=obj.PComponents(18)*mvnpdf([D],obj.mu(18,:,:),(obj.Sigma(:,:,18)));
P19=obj.PComponents(19)*mvnpdf([D],obj.mu(19,:,:),(obj.Sigma(:,:,19)));
P20=obj.PComponents(20)*mvnpdf([D],obj.mu(20,:,:),(obj.Sigma(:,:,20)));
    for p=1:1:length(D);
        p
        if
            (P1(p)>P2(p))&&(P1(p)>P3(p))&&(P1(p)>P4(p))&&(P1(p)>P5(p))&&(P1(
                p)>P6(p))&&(P1(p)>P7(p))&&(P1(p)>P8(p))&&(P1(p)>P9(p))&&(P1(p)>
                P10(p))&&(P1(p)>P11(p))&&(P1(p)>P12(p))&&(P1(p)>P13(p))&&(P1(p)
                >P14(p))&&(P1(p)>P15(p))&&(P1(p)>P16(p))&&(P1(p)>P17(p))&&(P1(p)
                )>P18(p))&&(P1(p)>P19(p))&&(P1(p)>P20(p))
                c=1
            elseif
                (P2(p)>P1(p))&&(P2(p)>P3(p))&&(P2(p)>P4(p))&&(P2(p)>P5(p))&&(P2(
                    p)>P6(p))&&(P2(p)>P7(p))&&(P2(p)>P8(p))&&(P2(p)>P9(p))&&(P2(p)>
                    P10(p))&&(P2(p)>P11(p))&&(P2(p)>P12(p))&&(P2(p)>P13(p))&&(P2(p)
                    >P14(p))&&(P2(p)>P15(p))&&(P2(p)>P16(p))&&(P2(p)>P17(p))&&(P2(p)
                    )>P18(p))&&(P2(p)>P19(p))&&(P2(p)>P20(p))
                    c=2
                elseif
                    (P3(p)>P1(p))&&(P3(p)>P2(p))&&(P3(p)>P4(p))&&(P3(p)>P5(p))&&(P3(
                        p)>P6(p))&&(P3(p)>P7(p))&&(P3(p)>P8(p))&&(P3(p)>P9(p))&&(P3(p)>
                        P10(p))&&(P3(p)>P11(p))&&(P3(p)>P12(p))&&(P3(p)>P13(p))&&(P3(p)
                        >P14(p))&&(P3(p)>P15(p))&&(P3(p)>P16(p))&&(P3(p)>P17(p))&&(P3(p)
                        )>P18(p))&&(P3(p)>P19(p))&&(P3(p)>P20(p))
                            c=3
                    elseif
                        (P4(p)>P1(p))&&(P4(p)>P2(p))&&(P4(p)>P3(p))&&(P4(p)>P5(p))&&(P4(
                            p)>P6(p))&&(P4(p)>P7(p))&&(P4(p)>P8(p))&&(P4(p)>P9(p))&&(P4(p)>
                            P10(p))&&(P4(p)>P11(p))&&(P4(p)>P12(p))&&(P4(p)>P13(p))&&(P4(p)
                            >P14(p))&&(P4(p)>P15(p))&&(P4(p)>P16(p))&&(P4(p)>P17(p))&&(P4(p)
                            )>P18(p))&&(P4(p)>P19(p))&&(P4(p)>P20(p))
                                c=4
                        elseif
                            (P5(p)>P1(p))&&(P5(p)>P2(p))&&(P5(p)>P3(p))&&(P5(p)>P4(p))&&(P5(
                                p)>P6(p))&&(P5(p)>P7(p))&&(P5(p)>P8(p))&&(P5(p)>P9(p))&&(P5(p)>
                                P10(p))&&(P5(p)>P11(p))&&(P5(p)>P12(p))&&(P5(p)>P13(p))&&(P5(p)
                                >P14(p))&&(P5(p)>P15(p))&&(P5(p)>P16(p))&&(P5(p)>P17(p))&&(P5(p)
                                )>P18(p))&&(P5(p)>P19(p))&&(P5(p)>P20(p))
                                    c=5
                            elseif
                                (P6(p)>P1(p))&&(P6(p)>P2(p))&&(P6(p)>P3(p))&&(P6(p)>P4(p))&&(P6(
                                    p)>P5(p))&&(P6(p)>P7(p))&&(P6(p)>P8(p))&&(P6(p)>P9(p))&&(P6(p)>
                                    P10(p))&&(P6(p)>P11(p))&&(P6(p)>P12(p))&&(P6(p)>P13(p))&&(P6(p)
                                    >P14(p))&&(P6(p)>P15(p))&&(P6(p)>P16(p))&&(P6(p)>P17(p))&&(P6(p)
                                    )>P18(p))&&(P6(p)>P19(p))&&(P7(p)>P20(p))
                                        c=6
                                elseif
                                    (P7(p)>P1(p))&&(P7(p)>P2(p))&&(P7(p)>P3(p))&&(P7(p)>P4(p))&&(P7(
                                        p)>P5(p))&&(P7(p)>P6(p))&&(P7(p)>P8(p))&&(P7(p)>P9(p))&&(P7(p)>
                                        P10(p))&&(P7(p)>P11(p))&&(P7(p)>P12(p))&&(P7(p)>P13(p))&&(P7(p)
                                        >P14(p))&&(P7(p)>P15(p))&&(P7(p)>P16(p))&&(P7(p)>P17(p))&&(P7(p)
                                        )>P18(p))&&(P7(p)>P19(p))&&(P7(p)>P20(p))

```



```

&(P16(p)>P5(p))&&(P16(p)>P6(p))&&(P16(p)>P7(p))&&(P16(p)>P8(p))
&&(P16(p)>P9(p))&&(P16(p)>P10(p))&&(P16(p)>P11(p))&&(P16(p)>P1
2(p))&&(P16(p)>P13(p))&&(P16(p)>P14(p))&&(P16(p)>P15(p))&&(P16(
p)>P17(p))&&(P16(p)>P18(p))&&(P16(p)>P19(p))&&(P16(p)>P20(p))
    c=16
elseif
(P17(p)>P1(p))&&(P17(p)>P2(p))&&(P17(p)>P3(p))&&(P17(p)>P4(p))&
&(P17(p)>P5(p))&&(P17(p)>P6(p))&&(P17(p)>P7(p))&&(P17(p)>P8(p))
&&(P17(p)>P9(p))&&(P17(p)>P10(p))&&(P17(p)>P11(p))&&(P17(p)>P1
2(p))&&(P17(p)>P13(p))&&(P17(p)>P14(p))&&(P17(p)>P15(p))&&(P17(
p)>P16(p))&&(P17(p)>P18(p))&&(P17(p)>P19(p))&&(P17(p)>P20(p))
    c=17
elseif
(P18(p)>P1(p))&&(P18(p)>P2(p))&&(P18(p)>P3(p))&&(P18(p)>P4(p))&
&(P18(p)>P5(p))&&(P18(p)>P6(p))&&(P18(p)>P7(p))&&(P18(p)>P8(p))
&&(P18(p)>P9(p))&&(P18(p)>P10(p))&&(P18(p)>P11(p))&&(P18(p)>P1
2(p))&&(P18(p)>P13(p))&&(P18(p)>P14(p))&&(P18(p)>P15(p))&&(P18(
p)>P16(p))&&(P18(p)>P17(p))&&(P18(p)>P19(p))&&(P18(p)>P20(p))
    c=18
elseif
(P19(p)>P1(p))&&(P19(p)>P2(p))&&(P19(p)>P3(p))&&(P19(p)>P4(p))&
&(P19(p)>P5(p))&&(P19(p)>P6(p))&&(P19(p)>P7(p))&&(P19(p)>P8(p))
&&(P19(p)>P9(p))&&(P19(p)>P10(p))&&(P19(p)>P11(p))&&(P19(p)>P1
2(p))&&(P19(p)>P13(p))&&(P19(p)>P14(p))&&(P19(p)>P15(p))&&(P19(
p)>P16(p))&&(P19(p)>P17(p))&&(P19(p)>P18(p))&&(P19(p)>P20(p))
    c=19
else
(P20(p)>P1(p))&&(P20(p)>P2(p))&&(P20(p)>P3(p))&&(P20(p)>P4(p))&
&(P20(p)>P5(p))&&(P20(p)>P6(p))&&(P20(p)>P7(p))&&(P20(p)>P8(p))
&&(P20(p)>P9(p))&&(P20(p)>P10(p))&&(P20(p)>P11(p))&&(P20(p)>P1
2(p))&&(P20(p)>P13(p))&&(P20(p)>P14(p))&&(P20(p)>P15(p))&&(P20(
p)>P16(p))&&(P20(p)>P17(p))&&(P20(p)>P18(p))&&(P20(p)>P19(p))
    c=20
end
if
(P1(p)>P2(p))&&(P1(p)>P3(p))&&(P1(p)>P4(p))&&(P1(p)>P5(p))&&(P1(
p)>P6(p))&&(P1(p)>P7(p))&&(P1(p)>P8(p))&&(P1(p)>P9(p))&&(P1(p)>
P10(p))&&(P1(p)>P11(p))&&(P1(p)>P12(p))&&(P1(p)>P13(p))&&(P1(p)
>P14(p))&&(P1(p)>P15(p))&&(P1(p)>P16(p))&&(P1(p)>P17(p))&&(P1(p)
>P18(p))&&(P1(p)>P19(p))&&(P1(p)>P20(p))
    c=1; s=13; d= fprintf('%d\n',s);
elseif
(P2(p)>P1(p))&&(P2(p)>P3(p))&&(P2(p)>P4(p))&&(P2(p)>P5(p))&&(P2(
p)>P6(p))&&(P2(p)>P7(p))&&(P2(p)>P8(p))&&(P2(p)>P9(p))&&(P2(p)>
P10(p))&&(P2(p)>P11(p))&&(P2(p)>P12(p))&&(P2(p)>P13(p))&&(P2(p)
>P14(p))&&(P2(p)>P15(p))&&(P2(p)>P16(p))&&(P2(p)>P17(p))&&(P2(p)
>P18(p))&&(P2(p)>P19(p))&&(P2(p)>P20(p))
    c=2; s=26; d= fprintf('%d\n',s);
elseif
(P3(p)>P1(p))&&(P3(p)>P2(p))&&(P3(p)>P4(p))&&(P3(p)>P5(p))&&(P3(
p)>P6(p))&&(P3(p)>P7(p))&&(P3(p)>P8(p))&&(P3(p)>P9(p))&&(P3(p)>
P10(p))&&(P3(p)>P11(p))&&(P3(p)>P12(p))&&(P3(p)>P13(p))&&(P3(p)
>P14(p))&&(P3(p)>P15(p))&&(P3(p)>P16(p))&&(P3(p)>P17(p))&&(P3(p)
>P18(p))&&(P3(p)>P19(p))&&(P3(p)>P20(p))
    c=3; s=39; d= fprintf('%d\n',s);
elseif
(P4(p)>P1(p))&&(P4(p)>P2(p))&&(P4(p)>P3(p))&&(P4(p)>P5(p))&&(P4(
p)>P6(p))&&(P4(p)>P7(p))&&(P4(p)>P8(p))&&(P4(p)>P9(p))&&(P4(p)>
P10(p))&&(P4(p)>P11(p))&&(P4(p)>P12(p))&&(P4(p)>P13(p))&&(P4(p)

```

```

>P14(p))&&(P4(p)>P15(p))&&(P4(p)>P16(p))&&(P4(p)>P17(p))&&(P4(p)
>P18(p))&&(P4(p)>P19(p))&&(P4(p)>P20(p))
    c=4; s=52; d= fprintf("%d\n",s);
    elseif
(P5(p)>P1(p))&&(P5(p)>P2(p))&&(P5(p)>P3(p))&&(P5(p)>P4(p))&&(P5(
p)>P6(p))&&(P5(p)>P7(p))&&(P5(p)>P8(p))&&(P5(p)>P9(p))&&(P5(p)>
P10(p))&&(P5(p)>P11(p))&&(P5(p)>P12(p))&&(P5(p)>P13(p))&&(P5(p)
>P14(p))&&(P5(p)>P15(p))&&(P5(p)>P16(p))&&(P5(p)>P17(p))&&(P5(p)
>P18(p))&&(P5(p)>P19(p))&&(P5(p)>P20(p))
    c=5; s=65; d= fprintf("%d\n",s);
    elseif
(P6(p)>P1(p))&&(P6(p)>P2(p))&&(P6(p)>P3(p))&&(P6(p)>P4(p))&&(P6(
p)>P5(p))&&(P6(p)>P7(p))&&(P6(p)>P8(p))&&(P6(p)>P9(p))&&(P6(p)>
P10(p))&&(P6(p)>P11(p))&&(P6(p)>P12(p))&&(P6(p)>P13(p))&&(P6(p)
>P14(p))&&(P6(p)>P15(p))&&(P6(p)>P16(p))&&(P6(p)>P17(p))&&(P6(p)
>P18(p))&&(P6(p)>P19(p))&&(P6(p)>P20(p))
    c=6; s=78; d= fprintf("%d\n",s);
    elseif
(P7(p)>P1(p))&&(P7(p)>P2(p))&&(P7(p)>P3(p))&&(P7(p)>P4(p))&&(P7(
p)>P5(p))&&(P7(p)>P6(p))&&(P7(p)>P8(p))&&(P7(p)>P9(p))&&(P7(p)>
P10(p))&&(P7(p)>P11(p))&&(P7(p)>P12(p))&&(P7(p)>P13(p))&&(P7(p)
>P14(p))&&(P7(p)>P15(p))&&(P7(p)>P16(p))&&(P7(p)>P17(p))&&(P7(p)
>P18(p))&&(P7(p)>P19(p))&&(P7(p)>P20(p))
    c=7; s=91; d= fprintf("%d\n",s);
    elseif
(P8(p)>P1(p))&&(P8(p)>P2(p))&&(P8(p)>P3(p))&&(P8(p)>P4(p))&&(P8(
p)>P5(p))&&(P8(p)>P6(p))&&(P8(p)>P7(p))&&(P8(p)>P9(p))&&(P8(p)>
P10(p))&&(P8(p)>P11(p))&&(P8(p)>P12(p))&&(P8(p)>P13(p))&&(P8(p)
>P14(p))&&(P8(p)>P15(p))&&(P8(p)>P16(p))&&(P8(p)>P17(p))&&(P8(p)
>P18(p))&&(P8(p)>P19(p))&&(P8(p)>P20(p))
    c=8; s=104; d= fprintf("%d\n",s);
    elseif
(P9(p)>P1(p))&&(P9(p)>P2(p))&&(P9(p)>P3(p))&&(P9(p)>P4(p))&&(P9(
p)>P5(p))&&(P9(p)>P6(p))&&(P9(p)>P7(p))&&(P9(p)>P8(p))&&(P9(p)>
P10(p))&&(P9(p)>P11(p))&&(P9(p)>P12(p))&&(P9(p)>P13(p))&&(P9(p)
>P14(p))&&(P9(p)>P15(p))&&(P9(p)>P16(p))&&(P9(p)>P17(p))&&(P9(p)
>P18(p))&&(P9(p)>P19(p))&&(P9(p)>P20(p))
    c=9; s=117; d= fprintf("%d\n",s);
    elseif
(P10(p)>P1(p))&&(P10(p)>P2(p))&&(P10(p)>P3(p))&&(P10(p)>P4(p))&
&(P10(p)>P5(p))&&(P10(p)>P6(p))&&(P10(p)>P7(p))&&(P10(p)>P8(p))
&&(P10(p)>P9(p))&&(P10(p)>P11(p))&&(P10(p)>P12(p))&&(P10(p)>P1
3(p))&&(P10(p)>P14(p))&&(P10(p)>P15(p))&&(P10(p)>P16(p))&&(P10(
p)>P17(p))&&(P10(p)>P18(p))&&(P10(p)>P19(p))&&(P10(p)>P20(p))
    c=10; s=130; d= fprintf("%d\n",s);
    elseif
(P11(p)>P1(p))&&(P11(p)>P2(p))&&(P11(p)>P3(p))&&(P11(p)>P4(p))&
&(P11(p)>P5(p))&&(P11(p)>P6(p))&&(P11(p)>P7(p))&&(P11(p)>P8(p))
&&(P11(p)>P9(p))&&(P11(p)>P10(p))&&(P11(p)>P12(p))&&(P11(p)>P1
3(p))&&(P11(p)>P14(p))&&(P11(p)>P15(p))&&(P11(p)>P16(p))&&(P11(
p)>P17(p))&&(P11(p)>P18(p))&&(P11(p)>P19(p))&&(P11(p)>P20(p))
    c=11; s=143; d= fprintf("%d\n",s);
    elseif
(P12(p)>P1(p))&&(P12(p)>P2(p))&&(P12(p)>P3(p))&&(P12(p)>P4(p))&
&(P12(p)>P5(p))&&(P12(p)>P6(p))&&(P12(p)>P7(p))&&(P12(p)>P8(p))
&&(P12(p)>P9(p))&&(P12(p)>P10(p))&&(P12(p)>P11(p))&&(P12(p)>P1
3(p))&&(P12(p)>P14(p))&&(P12(p)>P15(p))&&(P12(p)>P16(p))&&(P12(
p)>P17(p))&&(P12(p)>P18(p))&&(P12(p)>P19(p))&&(P12(p)>P20(p))
    c=12; s=156; d= fprintf("%d\n",s);

```

```

elseif
(P13(p)>P1(p))&&(P13(p)>P2(p))&&(P13(p)>P3(p))&&(P13(p)>P4(p))&
&(P13(p)>P5(p))&&(P13(p)>P6(p))&&(P13(p)>P7(p))&&(P13(p)>P8(p))
&&(P13(p)>P9(p))&&(P13(p)>P10(p))&&(P13(p)>P11(p))&&(P13(p)>P1
2(p))&&(P13(p)>P14(p))&&(P13(p)>P15(p))&&(P13(p)>P16(p))&&(P13(
p)>P17(p))&&(P13(p)>P18(p))&&(P13(p)>P19(p))&&(P13(p)>P20(p))
c=13; s=169; d= fprintf("%d\n",s);
elseif
(P14(p)>P1(p))&&(P14(p)>P2(p))&&(P14(p)>P3(p))&&(P14(p)>P4(p))&
&(P14(p)>P5(p))&&(P14(p)>P6(p))&&(P14(p)>P7(p))&&(P14(p)>P8(p))
&&(P14(p)>P9(p))&&(P14(p)>P10(p))&&(P14(p)>P11(p))&&(P14(p)>P1
2(p))&&(P14(p)>P13(p))&&(P14(p)>P15(p))&&(P14(p)>P16(p))&&(P14(
p)>P17(p))&&(P14(p)>P18(p))&&(P14(p)>P19(p))&&(P14(p)>P20(p))
c=14; s=182; d= fprintf("%d\n",s);
elseif
(P15(p)>P1(p))&&(P15(p)>P2(p))&&(P15(p)>P3(p))&&(P15(p)>P4(p))&
&(P15(p)>P5(p))&&(P15(p)>P6(p))&&(P15(p)>P7(p))&&(P15(p)>P8(p))
&&(P15(p)>P9(p))&&(P15(p)>P10(p))&&(P15(p)>P11(p))&&(P15(p)>P1
2(p))&&(P15(p)>P13(p))&&(P15(p)>P14(p))&&(P15(p)>P16(p))&&(P15(
p)>P17(p))&&(P15(p)>P18(p))&&(P15(p)>P19(p))&&(P15(p)>P20(p))
c=15; s=195; d= fprintf("%d\n",s);
elseif
(P16(p)>P1(p))&&(P16(p)>P2(p))&&(P16(p)>P3(p))&&(P16(p)>P4(p))&
&(P16(p)>P5(p))&&(P16(p)>P6(p))&&(P16(p)>P7(p))&&(P16(p)>P8(p))
&&(P16(p)>P9(p))&&(P16(p)>P10(p))&&(P16(p)>P11(p))&&(P16(p)>P1
2(p))&&(P16(p)>P13(p))&&(P16(p)>P14(p))&&(P16(p)>P15(p))&&(P16(
p)>P17(p))&&(P16(p)>P18(p))&&(P16(p)>P19(p))&&(P16(p)>P20(p))
c=16; s=208; d= fprintf("%d\n",s);
elseif
(P17(p)>P1(p))&&(P17(p)>P2(p))&&(P17(p)>P3(p))&&(P17(p)>P4(p))&
&(P17(p)>P5(p))&&(P17(p)>P6(p))&&(P17(p)>P7(p))&&(P17(p)>P8(p))
&&(P17(p)>P9(p))&&(P17(p)>P10(p))&&(P17(p)>P11(p))&&(P17(p)>P1
2(p))&&(P17(p)>P13(p))&&(P17(p)>P14(p))&&(P17(p)>P15(p))&&(P17(
p)>P16(p))&&(P17(p)>P18(p))&&(P17(p)>P19(p))&&(P17(p)>P20(p))
c=17; s=221; d= fprintf("%d\n",s);
elseif
(P18(p)>P1(p))&&(P18(p)>P2(p))&&(P18(p)>P3(p))&&(P18(p)>P4(p))&
&(P18(p)>P5(p))&&(P18(p)>P6(p))&&(P18(p)>P7(p))&&(P18(p)>P8(p))
&&(P18(p)>P9(p))&&(P18(p)>P10(p))&&(P18(p)>P11(p))&&(P18(p)>P1
2(p))&&(P18(p)>P13(p))&&(P18(p)>P14(p))&&(P18(p)>P15(p))&&(P18(
p)>P16(p))&&(P18(p)>P17(p))&&(P18(p)>P19(p))&&(P18(p)>P20(p))
c=18; s=234; d= fprintf("%d\n",s);
elseif
(P19(p)>P1(p))&&(P19(p)>P2(p))&&(P19(p)>P3(p))&&(P19(p)>P4(p))&
&(P19(p)>P5(p))&&(P19(p)>P6(p))&&(P19(p)>P7(p))&&(P19(p)>P8(p))
&&(P19(p)>P9(p))&&(P19(p)>P10(p))&&(P19(p)>P11(p))&&(P19(p)>P1
2(p))&&(P19(p)>P13(p))&&(P19(p)>P14(p))&&(P19(p)>P15(p))&&(P19(
p)>P16(p))&&(P19(p)>P17(p))&&(P19(p)>P18(p))&&(P19(p)>P20(p))
c=19; s=247; d= fprintf("%d\n",s);
else
(P20(p)>P1(p))&&(P20(p)>P2(p))&&(P20(p)>P3(p))&&(P20(p)>P4(p))&
&(P20(p)>P5(p))&&(P20(p)>P6(p))&&(P20(p)>P7(p))&&(P20(p)>P8(p))
&&(P20(p)>P9(p))&&(P20(p)>P10(p))&&(P20(p)>P11(p))&&(P20(p)>P1
2(p))&&(P20(p)>P13(p))&&(P20(p)>P14(p))&&(P20(p)>P15(p))&&(P20(
p)>P16(p))&&(P20(p)>P17(p))&&(P20(p)>P18(p))&&(P20(p)>P19(p))
c=20; s=255; d= fprintf("%d\n",s);
end
fileID = fopen('C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\Jupiter\SINIF RENK\jupiter.txt','a+');

```

```

fprintf(fileID, '%3.8f\n',s');
fclose(fileID);
end
load('C:\Users\EMRE\Desktop\DOKTORA TEZI\Veriler\Jupiter\SINIF
RENK\jupiter.txt');
z=load('C:\Users\EMRE\Desktop\DOKTORA TEZI\Veriler\Jupiter\SINIF
RENK\jupiter.txt');
E(:,,1)=(reshape(z,1825,1691));
subplot(4,4,4)
hold on
imshow(E(:,,1),colormap(prism(275)))
hold off
imwrite(E(:,,1),'C:\Users\EMRE\Desktop\DOKTORA
TEZI\Veriler\Jupiter\GORUNTU\emjupiter.jpeg');
imwrite(E(:,,1),colormap(prism(250)), 'C:\Users\EMRE\Desktop\DOKTOR
A TEZI\Veriler\Jupiter\GORUNTU\emjupiter.tif');
subplot(4,4,5)
hold on
imshow(E(:,,1),colormap(prism(250)))
hold off

```

4.2.10. EM Algoritması Yardımı ile Yapılan Sınıflandırma Sonuçlarının Klasik Sınıflandırıcı Sonuçları ile Karşılaştırılması

Özellikle uzaklık ölçütünü esas alan ve olasılık yoğunluk fonksiyonu kullanmayan klasik uzaktan algılama kümeleme ve sınıflandırma tekniklerinden üçü; ön bilgilendirmesiz olarak Isodata, ve ön bilgilendirmeli olarak en kısa uzaklık ve Mahalanobis uzaklık sınıflandırmaları ile olasılık yoğunluk fonksiyonu esaslı sınıflandırma yapan EM algoritmasının karşılaştırmaları yapılmıştır. Bu karşılaştırma görüntü sonuçları üzerinde bazı önemli nirengi noktaları alınarak yapılmıştır. Karşılaştırmalar için bazı kategoriler oluşturulmuştur; tüm sınıflandırması yapılan uzaktan algılama verileri üç bantlı olup yer yüzüne ait olan verilerin tahmini sınıf sayıları iki, üç, dört, beş ve 15 olup, Güneş sistemimizde bulunan Satürn ve Jüpiter gezegenlerine ait veriler; Satürn halkaları verisi ile Jüpiter'in atmosferindeki fırtına verisi için tahmini sınıf sayısı 20'dir.

Isodata ön bilgilendirmesiz kümeleme analizi için EM algoritması ile başlangıçta girilen tahmini küme sayısının aynı olmasına dikkat edilmiştir. Ön bilgilendirmeli sınıflandırma analizleri en kısa uzaklık ve Mahalanobis uzaklık teknikleri için aynı kategorilerdeki EM algoritmasında tahmin edilen sınıf sayısı kadar ön bilgilendirme sınıfı oluşturulmuş ve yapılan ön bilgilendirmelerin gerçeği yansıtmasına özen gösterilmiştir.

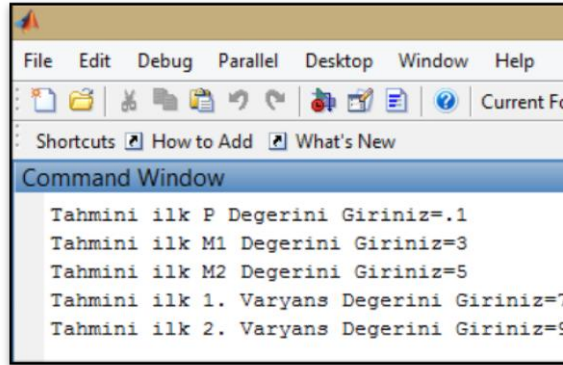
Tüm kategoriler için orijinal veriler ile modifiyesiz ve modifiyeli EM algoritması yardımı ile elde edilen sınıflandırma sonuçları ve Isodata, en kısa uzaklık, Mahalanobis uzaklıkları sınıflandırma sonuçları ortaya konularak nirengi noktaları ile önemli yer ve konumları hangi sınıflandırıcıların daha güvenilir ve etkin olarak gerçekleştirdiği tartışılarak ortaya konulmuştur.

5. ARAŞTIRMA BULGULARI

4. Materyal bölümünün 4.2 Yöntem başlığının altında yer alan farklı bant ve sınıf sayılarına göre EM algoritmasının matlab kodu yazılarak yapılan uygulama sonuçları, ne amaçla yapıldığı, nasıl yapıldığı ve hangi sorunlarla karşılaşıldığı anlatılacaktır.

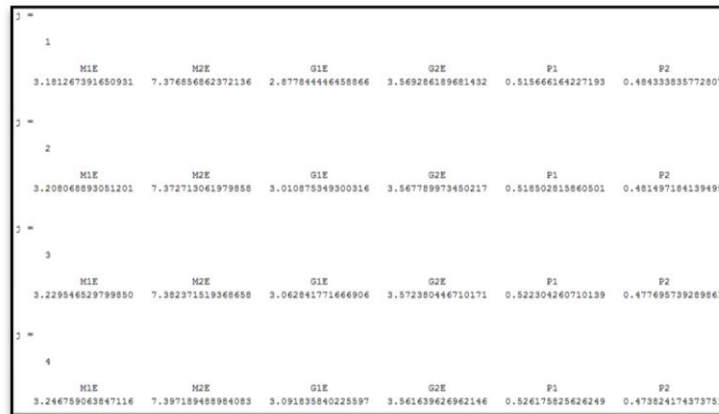
5.1. EM Algoritmasının İki Bileşenli Gauss Dağılımı için Uygulanması

İlk uygulamaya konunun daha kolay anlaşılması için 14 adet hipotetik veri ile başlanırsa: Bu hipotetik veriler sırası ile 1, 1.3, 2, 2.1, 4, 4.7, 4.8, 5, 5.3, 5.5, 7, 8, 8.5, 9, 10 olsun bu 14 verinin iki bileşenli bir karma Gauss modeli olduğunu düşündüğümüzde Agoritma (2.1)'in gerektiği yerlerinde Denklem (2.74), (2.75), (2.76), (2.77) ve (2.78)'e uygun olarak yazılmış matlab kodu yardımı ile analiz ilk değerlerin girişi ve sonuçları aşağıdaki gibi olur:



```
File Edit Debug Parallel Desktop Window Help
Shortcuts How to Add What's New
Command Window
Tahmini ilk P Degerini Giriniz=.1
Tahmini ilk M1 Degerini Giriniz=3
Tahmini ilk M2 Degerini Giriniz=5
Tahmini ilk 1. Varyans Degerini Giriniz=7
Tahmini ilk 2. Varyans Degerini Giriniz=9
```

Şekil 5.1. EM Algoritmasını başlatan ilk değerlerin girilmesi



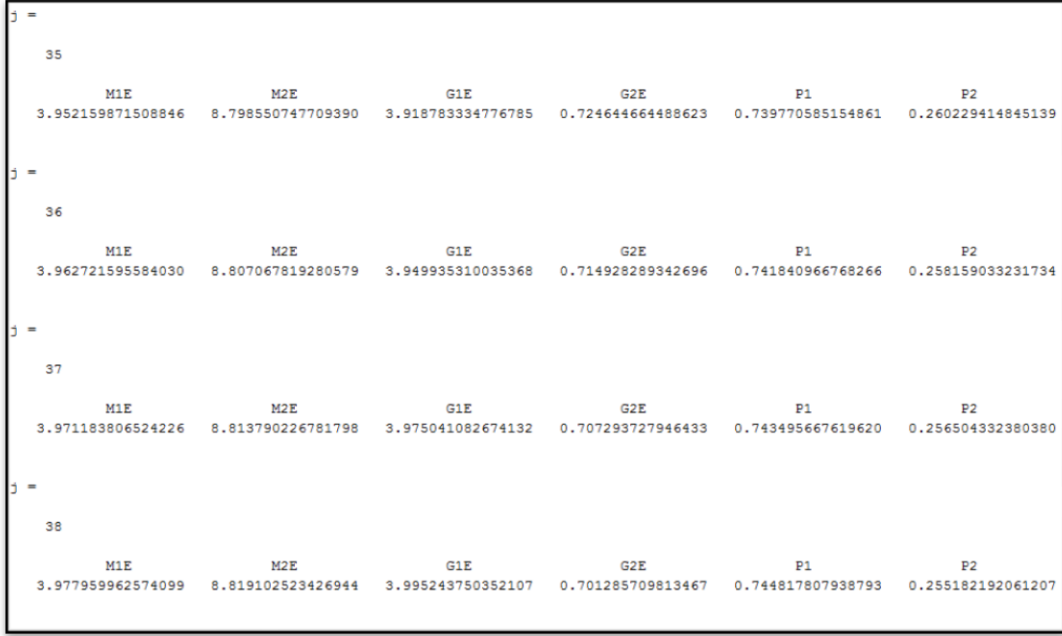
```
1
M1E M2E G1E G2E P1 P2
3.181267391650931 7.376856662372136 2.877844446458866 3.569286189681432 0.515666164227193 0.484333835772807

2
M1E M2E G1E G2E P1 P2
3.208068893051201 7.372713061979858 3.010875349300316 3.567789973450217 0.518502815860501 0.481497184139499

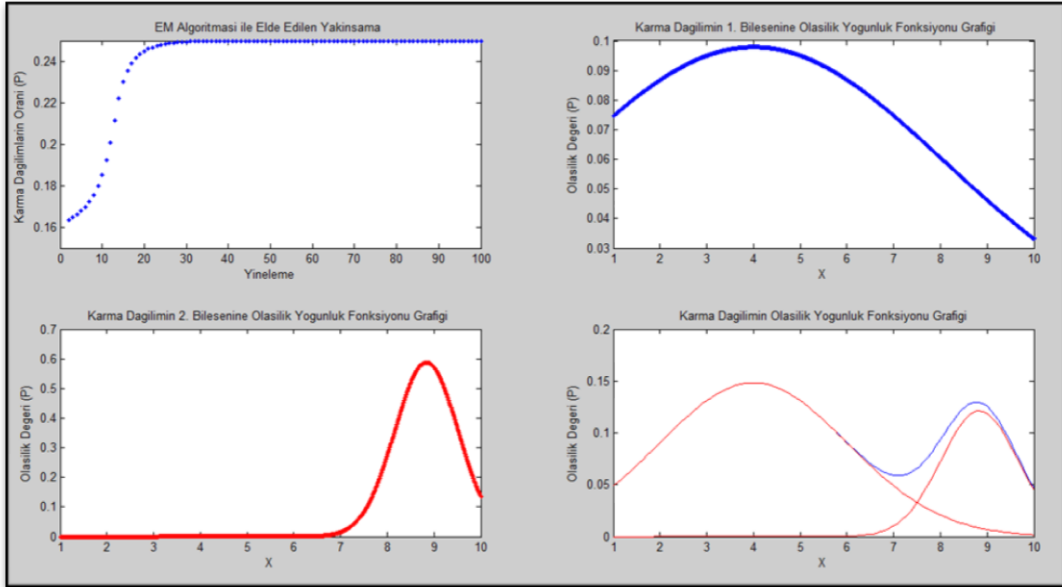
3
M1E M2E G1E G2E P1 P2
3.229546529799850 7.382371519368658 3.062841771666906 3.572380446710171 0.522304260710139 0.477695739289861

4
M1E M2E G1E G2E P1 P2
3.246759063847116 7.397189488984083 3.091835840225597 3.561639624962146 0.526175825626249 0.473824174373751
```


Şekil 5.2. İlk değerlerin girilmesinden sonra EM algoritmasının çalışması ve yinelenmeler esnasında anlık ekran görüntüsü (matlab çıktısı)




Şekil 5.3. EM algoritmasında yakınsamanın başlaması esnasındaki anlık ekran görüntüsü
(matlab çıktısı)




Şekil 5.4. EM algoritması tamamlandıktan sonraki özet durum
(matlab çıktısı)




Şekil 5.5. EM Algoritmasında yakınsama sürecine kadar olan yinmelerin grafiksel gösterimi (matlab çıktısı)



Şekil 5.6. EM algoritması süreci tamamlandıktan sonra birinci bileşene ait dağılım grafiği (matlab çıktısı)



Şekil 5.7. EM algoritması süreci tamamlandıktan sonra ikinci bileşene ait dağılım grafiği (matlab çıktısı)



Şekil 5.8. EM algoritması tamamlandıktan oluşan iki bileşenli karma dağılım modelinin grafiği (matlab çıktısı)

EM algoritması tamamlandıktan sonra elde edilen parametre tahminler aşağıdaki gibi olur:

$$\hat{\mu}_1 = 4.00$$

$$\hat{\sigma}_1^2 = 4.08$$

$$\hat{\mu}_2 = 8.84$$

$$\hat{\sigma}_2^2 = 0.68$$


$$\hat{\pi} = 0.25$$

Bu durumda varsayımsal verilere ait iki bileşenli Gauss karma modelin denklemini aşağıdaki gibi olur :

$$Y = 0.25 \cdot N(4, 4.08) + 0.75 \cdot N(8.84, 0.68)$$

5.2. EM Algoritmasının İki Bileşenli Uzaktan Algılama Verisine Uygulanması

NASA'nın sayfasında bulunana Dukono bölgesinin sadece deniz ve kara sınıflarını içeren küçük bir parçasına EM algoritması uygulanmıştır. Bölüm 4'deki Şekil 4.2 tekrar aşağıda verilmiştir:



Şekil 4.2. Dukono bölgesi uzaktan algılama verisinin küçük iki bileşenli örneklem Görüntüsü (Anonim, 2014)

İlk tahmin değerlerinin girişi Şekil (5.9)'da görülmektedir. Şekil (5.9)'da 3.770 adet piksel bulunmaktadır. EM algoritması ilk değerlerin girilmesinden sonra tek bant için 3.770 adet piksele Algoritma (2.1)'i uygular. Bu amaçla değerlerin girilmesine ilişkin ekran görüntüsü Şekil (5.9)'da görülmektedir.


```
Tahmini ilk P Degerini Giriniz=.8
Tahmini ilk M1 Degerini Giriniz=5
Tahmini ilk M2 Degerini Giriniz=100
Tahmini ilk 1. Varyans Degerini Giriniz=150
Tahmini ilk 2. Varyans Degerini Giriniz=150
```

Şekil 5.9. Uzaktan algılanmış Dukono civarı verisi için EM algoritmasını başlatan ilk tahmin değerlerinin girilmesi


Şekil (5.11)'de algoritma çalışmaya başladıktan sonra anlık ekran görüntüsü yer almaktadır:

VERI NO	VERI	P1	P2	SINIF	PARLAKLIK
1.0e+03 *					
3.1000000000000000	0.0040000000000000	0.000115327850911	0.000000342144831	0.0010000000000000	0.0450000000000000
VERI NO	VERI	P1	P2	SINIF	PARLAKLIK
1.0e+03 *					
3.1010000000000000	0.0040000000000000	0.000115327850911	0.000000342144831	0.0010000000000000	0.0450000000000000
VERI NO	VERI	P1	P2	SINIF	PARLAKLIK
1.0e+03 *					
3.1020000000000000	0.0040000000000000	0.000115327850911	0.000000342144831	0.0010000000000000	0.0450000000000000
VERI NO	VERI	P1	P2	SINIF	PARLAKLIK
1.0e+03 *					
3.1030000000000000	0.0040000000000000	0.000115327850911	0.000000342144831	0.0010000000000000	0.0450000000000000
VERI NO	VERI	P1	P2	SINIF	PARLAKLIK
1.0e+03 *					


Şekil 5.10. Uzaktan algılanmış Dukono civarı verisine ait ilk değerlerin girilmesinden sonra EM algoritmasının çalışması ve yinelemeler (matlab çıktısı)




Şekil 5.11. Uzaktan algılanmış Dukono civarı verisi için iki karma modeline ait ağırlıklı olasılıkların iterasyon sonucunda yakınsama durumu (matlab çıktısı)



Şekil 5.12. Dukono civarı verisi için birinci karma modele yani kara sınıfına ait olasılık yoğunluk fonksiyonu eğrisi (matlab çıktısı)




Şekil 5.13. Dukono civarı verisi için ikinci karma modele yani deniz sınıfına ait olasılık yoğunluk fonksiyonu eğrisi (matlab çıktısı)



Şekil 5.14. EM algoritması tamamlandıktan oluşan Dukono civarı verisi için kara ve denize ait karma modelin olasılık yoğunluk fonksiyonun grafiği (matlab çıktısı)



Şekil 5.15. Dukono civarı verisi için EM algoritması ile elde edilen karma modeli parametre tahminleri ile elde edilen sınıflandırılmış görüntü (matlab çıktısı)



Şekil 5.16 Dukono civarı verisi (a) için EM algoritması yardımı ile sınıflandırmış görüntü (b) ve orjinal görüntü (a)

Bu aşamada tek bant ya da tek renk spektral aralığı için EM algoritması modifiyesiz olarak başarılı bir şekilde sınıflandırma yapmıştır.

5.3. EM Algoritmasının Üç Bantlı İki Bileşenli Uzaktan Algılama Verisine Uygulanması

Elde edilen her bir sınıf ve banta ait ortalamalar, karma oranlar, varyans kovaryans matrisleri değerleri aşağıda verilmiştir:

Bileşen 1:

Karma oranı: 0.507847

Ortalama: 1.0e+03 *

5.548360478911937 7.697444398659375 8.871877490132569

Bileşen 2:

Karma oranı: 0.492153

Ortalama: 1.0e+03 *

5.289898295220025 7.409811390977534 8.634819015896653

Her bir bileşene ait varyans kovaryans matrisleri

Bileşen (:,:,1) =

1.0e+04 *

1.697468907281560 1.466712851438596 1.174011354383179

1.466712851438596 1.427975692728760 1.148449714516405

1.174011354383179 1.148449714516405 0.939832582533627

Bileşen (:,:,2) =

1.0e+03 *

2.691067618713432 2.463839019302114 1.538801550091912

2.463839019302114 2.742678788215696 1.931623338260400

1.538801550091912 1.931623338260400 1.765669490567675

Her bir bileşen için karma oranlar

0.507847370060203 0.492152629939797

Karma ortalamalar


1.0e+03 *

5.548360478911937 7.697444398659375 8.871877490132569

5.289898295220025 7.409811390977534 8.634819015896653


EM algoritması sonucu elde edilen parametre tahminleri ve karma model yardımı ile gerçekleştirilmiş olan sınıflandırma işlemi sonucunun görüntüsü Şekil (5.17)'de mevcuttur.

Şekil (5.18)'de ön bilgilendirmesiz Isodata sınıflandırma analizi sonucu görüntüsü, Şekil (5.19)'da yapılan ön bilgilendirme ve Şekil (5.21)'de yapılan bu ön bilgilendirmeye bağlı olarak en kısa uzaklık sınıflandırma analizi sonucu görüntüsü ve Şekil (5.22)'de yine yapılan bu ön bilgilendirmeye bağlı olarak en Mahalanobis uzaklık sınıflandırma analizi sonucu görüntüsü yer almaktadır.




Şekil 5.17. Üç bant ve iki sınıf için EM algoritması sonucu elde edilen parametre tahminleri ve karma model yardımı ile gerçekleştirilmiş olan sınıflandırma işlemi sonucunun görüntüsü (matlab'dan elde edilen resim dosyasının erdas programında açılmış hali)

Aynı uzaktan algılama verisi için Isodata, en kısa uzaklık ve Mahalanobis uzaklık sonuçları aşağıda verilmiştir:




Şekil 5.18. Üç bant ve iki sınıf için Isodata sınıflandırma sonucu görüntüsü



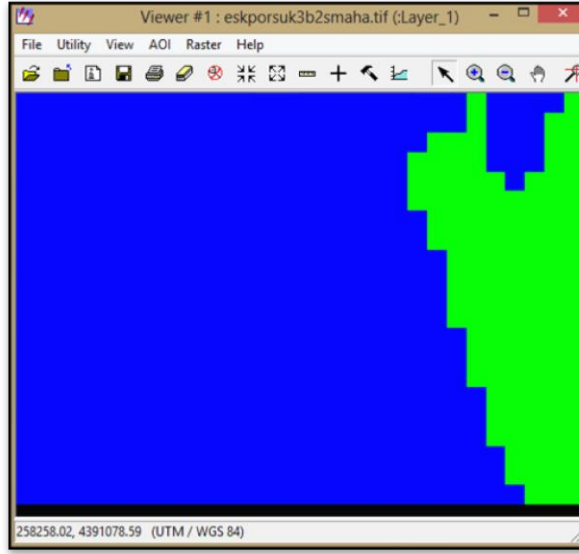
Şekil 5.19. Üç bant ve iki sınıf için yapılan ön bilgilendirme

Class #	Signature Name	Color	Red	Green	Blue	Value	Order
1	derin_su	Blue	0.653	0.687	0.967	1	1
2	derin_su	Red	0.000	0.000	1.000	2	2

Şekil 5.20. Üç bant ve iki sınıf için yapılan ön bilgilendirme değerleri



Şekil 5.21. Üç bant ve iki sınıf için en kısa uzaklık sınıflandırma sonucu görüntüsü



Şekil 5.22. Üç bant ve iki sınıf için Mahalanobis uzaklık sınıflandırma sonucu görüntüsü

5.4. EM Algoritmasının Üç Bantlı Üç Bileşenli Uzaktan Algılama Verisine Uygulanması

Elde edilen her bir sınıf ve banta ait ortalamalar, karma oranlar, varyans kovaryans matrisleri değerleri aşağıda verilmiştir:

Bileşen 1:

Karma oranı: 0.257752

Ortalama: 1.0e+03 *

8.758783060833073 9.108807492472112 9.408472669030946

Bileşen 2:

Karma oranı: 0.217234

Ortalama: 1.0e+04 *

1.482405344749404 1.195338943378736 1.123326636908667

Bileşen 3:

Karma oranı 0.525014

Ortalama: 1.0e+03 *

5.445289885891840 7.444517795029951 8.287514116857949

Kovaryans (:,:,1) =


1.0e+06 *

8.746487421434521 4.141857540202074 2.775788718984652

4.141857540202074 1.973141377622174 1.322767619726550
2.775788718984652 1.322767619726550 0.887442381362212
Kovaryans (:,:,2) =
1.0e+06 *
1.191597685016492 0.685149426943325 0.584129328170627
0.685149426943325 0.414562993154950 0.360179842967355
0.584129328170627 0.360179842967355 0.316683223934774
Kovaryans (:,:,3) =
1.0e+03 *
1.967438561215618 1.391567308631918 1.185587969009835
1.391567308631918 1.813517507900127 1.727687588923108
1.185587969009835 1.727687588923108 1.913116171568733
Her bir bileşen için karma oranlar:
0.257752153778350 0.217233989263746 0.525013856957904
Karma ortalamalar:
1.0e+04 *
0.875878306083307 0.910880749247211 0.940847266903095
1.482405344749404 1.195338943378736 1.123326636908667
0.544528988589184 0.744451779502995 0.828751411685795

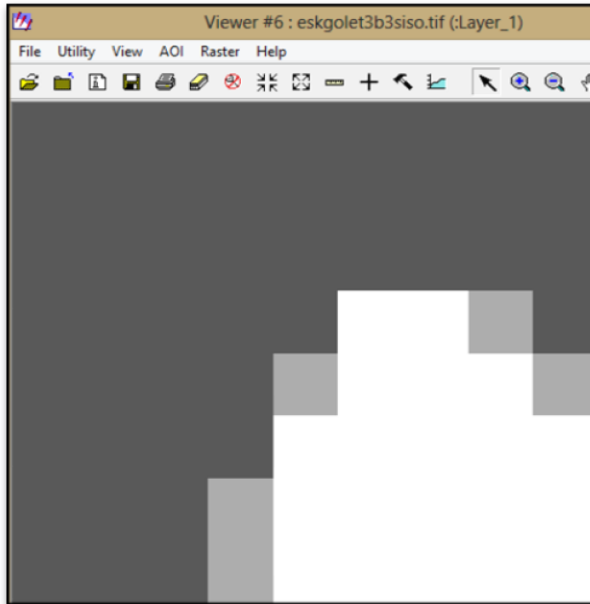
EM algoritması sonucu elde edilen parametre tahminleri ve karma model yardımı ile gerçekleştirilmiş olan sınıflandırma işlemi sonucunun görüntüsü Şekil (5.23)'de mevcuttur:

Şekil (5.25)'de ön bilgilendirmesiz Isodata sınıflandırma analizi sonucu görüntüsü, Şekil (5.26)'da yapılan ön bilgilendirme ve Şekil (5.27)'de yapılan bu ön bilgilendirmeye bağlı olarak en kısa uzaklık sınıflandırma analizi sonucu görüntüsü ve Şekil (5.28)'de yine yapılan bu ön bilgilendirmeye bağlı olarak en Mahalanobis uzaklık sınıflandırma analizi sonucu görüntüsü yer almaktadır.

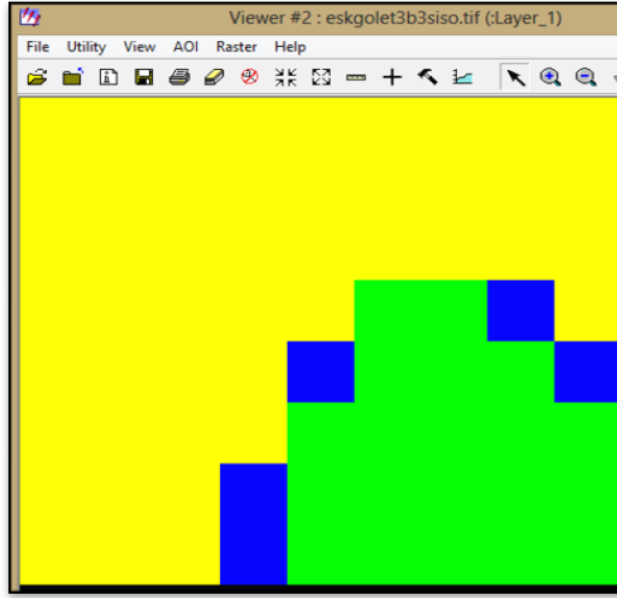


Şekil 5.23. Üç bant ve üç sınıf için EM algoritması sonucu elde edilen parametre tahminleri ve karma model yardımı ile gerçekleştirilmiş olan sınıflandırma analizi sonucu görüntüsü (matlab'dan elde edilen resim dosyasının erdasta açılmış hali)

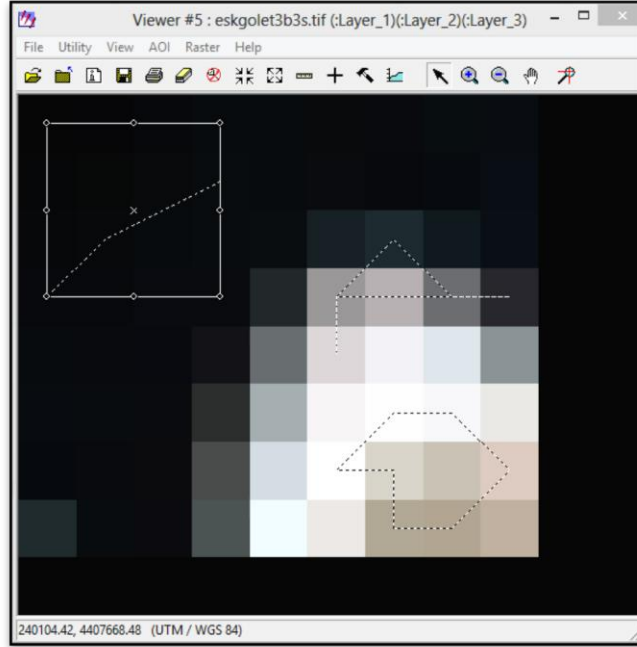
Aynı uzaktan algılama verisi için Isodata, en kısa uzaklık ve Mahalanobis uzaklık sonuçları aşağıda verilmiştir:




Şekil 5.24. Üç bant ve üç sınıf için Isodata sınıflandırma sonucu gri görüntüsü



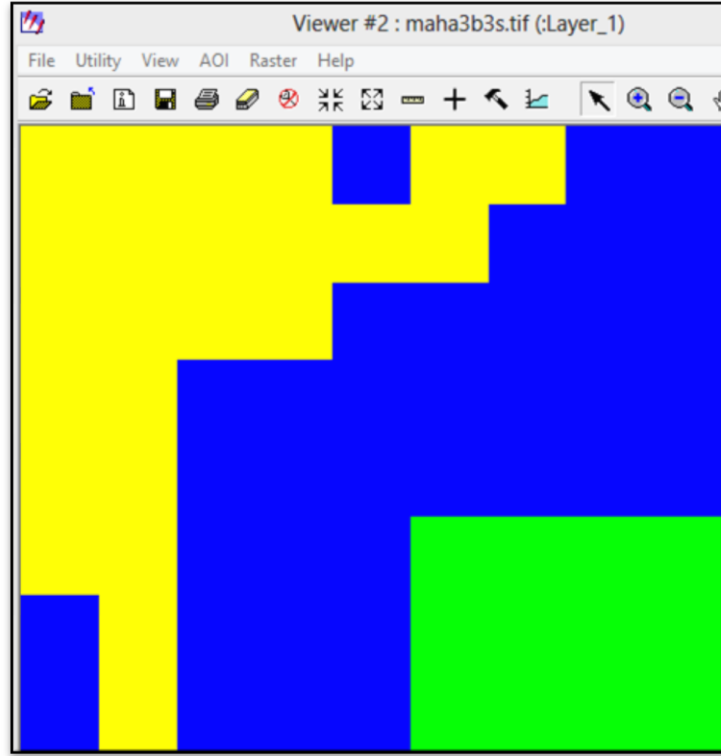
Şekil 5.25. Üç bant ve üç sınıf için Isodata sınıflandırma sonucu renkli görüntüsü



Şekil 5.26. Üç bant ve üç sınıf için yapılan ön bilgilendirme



Şekil 5.27. Üç bant ve üç sınıf için en kısa uzaklık sınıflandırma sonucu görüntüsü



Şekil 5.28. Üç bant ve üç sınıf için Mahalanobis uzaklık sınıflandırma sonucu görüntüsü

5.5. EM Algoritmasının Üç Banlı Dört Bileşenli Uzaktan Algılama Verisine Uygulanması

Elde edilen her bir sınıf ve banta ait ortalamalar, karma oranlar, varyans kovaryans matrisleri değerleri aşağıda verilmiştir:

Bileşen 1:

Karma Oranı: 0.408234

Ortalama: $1.0e+04$ *

1.189586464771802 1.020617045059868 0.967977913052593

Bileşen 2:

Karma Oranı: 0.257201

Ortalama: $1.0e+04$ *

1.373273312303506 1.147833541562229 1.089030809950738

Bileşen 3:

Karma Oranı: 0.183570

Ortalama: $1.0e+03$ *

5.362877796833316 7.408895357868980 8.249761603708526

Bileşen 4:

Karma Oranı: 0.150995

Ortalama: $1.0e+03$ *

8.111521070326283 9.311164881553571 9.722863952746732

Bileşenlerin varyans-kovaryans matrisleri

Bileşen varyans-kovaryans (:,:,1) =

$1.0e+06$ *

1.213531100081733 0.227322553745503 0.254143213894386
0.227322553745503 0.147828626030591 0.109085745017517
0.254143213894386 0.109085745017517 0.094891881321983

Bileşen varyans-kovaryans (:,:,2) =

$1.0e+06$ *

2.387984074161945 1.313836925289563 1.020732306193458
1.313836925289563 0.991635725135427 0.761560051459371
1.020732306193458 0.761560051459371 0.650165595834523

Bileşen varyans-kovaryans (:,:,3) =

$1.0e+04$ *

0.397307544429288 0.465701707614970 0.432565431466588
0.465701707614970 0.948320835444549 0.952863056055521
0.432565431466588 0.952863056055521 1.018868120153711

Bileşen varyans-kovaryans (:,:,4) =

1.0e+06 *

6.460784265648099	2.816472517959593	2.088076150642902
2.816472517959593	1.389655198911246	1.034684436111196
2.088076150642902	1.034684436111196	0.778561497234240

Her bir bileşen için karma oranlar:

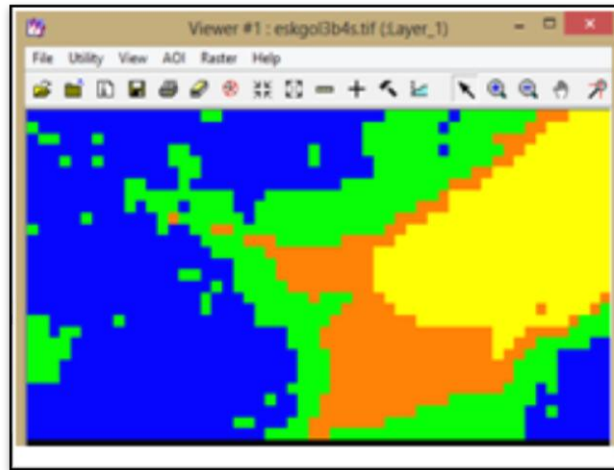
0.408233715866170	0.257201227394030	0.183569666106269
0.150995390633531		

Karma Ortalamalar =


1.0e+04 *

1.189586464771802	1.020617045059868	0.967977913052593
1.373273312303506	1.147833541562229	1.089030809950738
0.536287779683332	0.740889535786898	0.824976160370853
0.811152107032628	0.931116488155357	0.972286395274673

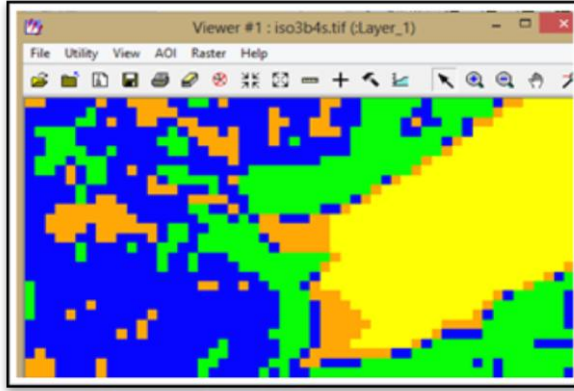
EM algoritması sonucu elde edilen parametre tahminleri ve karma model yardımı ile gerçekleştirilmiş olan sınıflandırma işlemi sonucunun görüntüsü Şekil (5.29)'da mevcuttur. Şekil (5.31)'de ön bilgilendirmesiz Isodata sınıflandırma analizi sonucu görüntüsü, Şekil (5.32)'de yapılan ön bilgilendirme ve Şekil (5.33)'de yapılan bu ön bilgilendirmeye bağlı olarak en kısa uzaklık sınıflandırma analizi sonucu görüntüsü ve Şekil (5.34)'de yine yapılan bu ön bilgilendirmeye bağlı olarak en Mahalanobis uzaklık sınıflandırma analizi sonucu görüntüsü yer almaktadır.



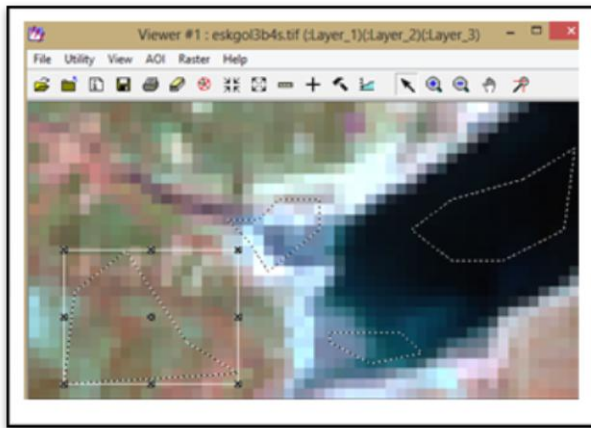
Şekil 5.29. Üç bant ve dört sınıf tahmini için EM algoritması sonucu elde edilen parametre tahminleri ve karma model yardımı ile gerçekleştirilmiş olan sınıflandırma analizi sonucunun görüntüsü (matlab'dan elde edilen resim dosyasının erdas'ta açılmış hali)




Şekil 5.30. Üç bant ve dört sınıf için Isodata kümeleme analizi sonucu gri ton görüntüsü



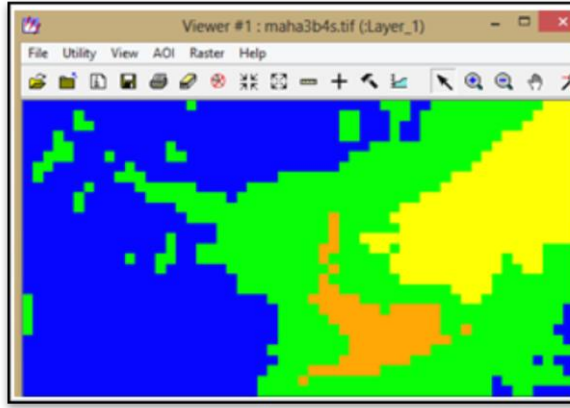
Şekil 5.31. Üç bant ve dört sınıf tahmini için Isodata kümeleme analizi sonucu renkli görüntüsü



Şekil 5.32. Üç bant ve dört sınıf tahmini için yapılan ön bilgilendirme



Şekil 5.33. Üç bant ve dört sınıf tahmini için en kısa uzaklık sınıflandırma sonucu görüntüsü



Şekil 5.34. Üç bant ve dört sınıf tahmini için Mahalanobis uzaklık sınıflandırma sonucu görüntüsü

5.6. EM Algoritmasının Üç Bantlı Beş Bileşenli Uzaktan Algılama Verisine Uygulanması

Elde edilen her bir sınıf ve banta ait ortalamalar, karma oranlar, varyans kovaryans matrisleri değerleri aşağıda verilmiştir:

Bileşen 1:

Karma oran: 0.231760

Ortalama: 1.0e+04 *

1.423095840491669 1.165475286538938 1.102396692453896

Bileşen 2:

Karma oran: 0.120285

Ortalama: 1.0e+03 *

7.905788435116903 9.131974060565531 9.571409648411096

Bileşen 3:

Karma oran: 0.215575

Ortalama: 1.0e+03 *

5.376193256441919 7.382695229758007 8.221906440874301

Bileşen 4:

Ortalama: 0.267980

Mean: 1.0e+04 *

1.287469066024700 1.040146662080440 0.992866639140232

Bileşen 5:

Karma oran: 0.164400

Ortalama: 1.0e+04 *

1.125079671061904 1.015715829639577 0.957064683935106

Karma oranları:

0.231760110854270 0.120284690114134 0.215575419847950

0.267979925253117 0.164399853930529

Varyans-Kovaryans matrisleri

Bileşen (:,:,1) =

1.0e+06 *

2.527392059390872 1.513249115559163 1.024738084883908

1.513249115559163 1.136023168441075 0.797744913835188

1.024738084883908 0.797744913835188 0.624834205497286

Bileşen (:,:,2) =

1.0e+06 *

5.717258153962739 2.591176564634648 1.895246152120259

2.591176564634648 1.337362013738391 0.988401341594417

1.895246152120259 0.988401341594417 0.740257616538093

Bileşen (:,:,3) =

1.0e+03 *

3.930100865319643 3.546644782222325 3.264511607053322

3.546644782222325 6.361408146284854 6.158320196961271

3.264511607053322 6.158320196961271 6.365342062253283

Bileşen (:,:,4) =

1.0e+05 *

8.092128108360765 2.262115368461355 1.795470465346876

2.262115368461355 2.661606096391446 1.561706195891579

1.795470465346876 1.561706195891579 1.084292381806763

Bileşen (:,:,5) =

1.0e+05 *

3.027975515413826 0.959529249035565 0.803861532607190

0.959529249035565 0.886812813295903 0.636817706823604

0.803861532607190 0.636817706823604 0.483403573798418

Karma Ortalamaları:

1.0e+04 *

1.423095840491669 1.165475286538938 1.102396692453896

0.790578843511690 0.913197406056553 0.957140964841110

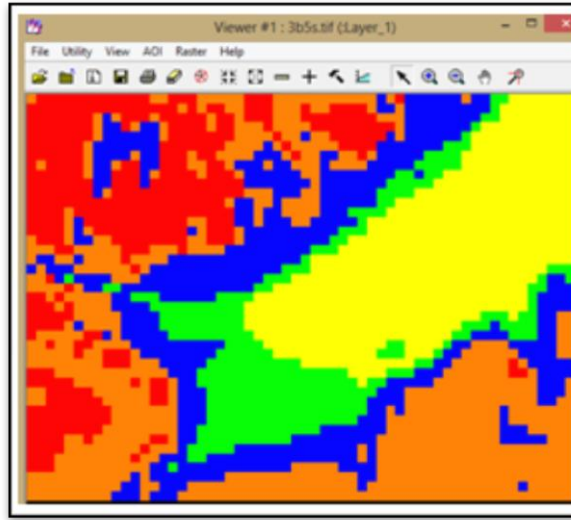
0.537619325644192 0.738269522975801 0.822190644087430

1.287469066024700 1.040146662080440 0.992866639140232

1.125079671061904 1.015715829639577 0.957064683935106


EM algoritması sonucu elde edilen parametre tahminleri ve karma model yardımı ile gerçekleştirilmiş olan sınıflandırma işlemi sonucunun görüntüsü Şekil (5.35)'de mevcuttur.

Şekil (5.37)'de ön bilgilendirmesiz Isodata sınıflandırma analizi sonucu görüntüsü, Şekil (5.38)'da yapılan ön bilgilendirme ve Şekil (5.39)'de yapılan bu ön bilgilendirmeye bağlı olarak en kısa uzaklık sınıflandırma analizi sonucu görüntüsü ve Şekil (5.40)'de yine yapılan bu ön bilgilendirmeye bağlı olarak en Mahalanobis uzaklık sınıflandırma analizi sonucu görüntüsü yer almaktadır.

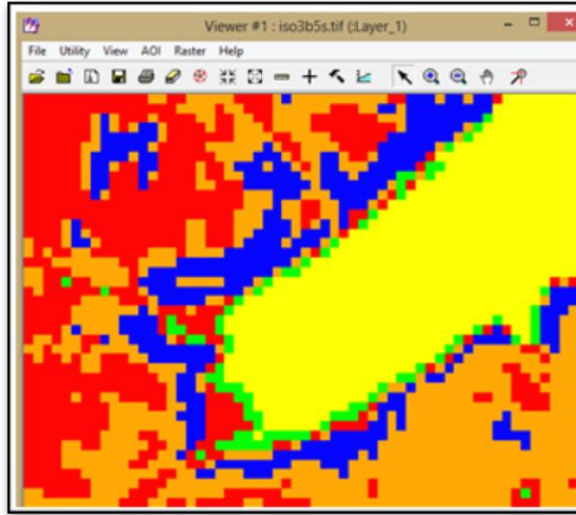


Şekil 5.35. Üç bant ve beş sınıf tahmini için EM algoritması sonucu elde edilen parametre tahminleri ve karma model yardımı ile gerçekleştirilmiş olan sınıflandırma analizi sonucunun görüntüsü (matlab'dan elde edilen resim dosyasının erdasta açılmış hali)


Aynı uzaktan algılama verisi için Isodata, en kısa uzaklık ve Mahalanobis uzaklık sonuçları aşağıda verilmiştir:




Şekil 5.36. Üç bant ve beş sınıf tahmini için Isodata sınıflandırma sonucu gri ton görüntüsü



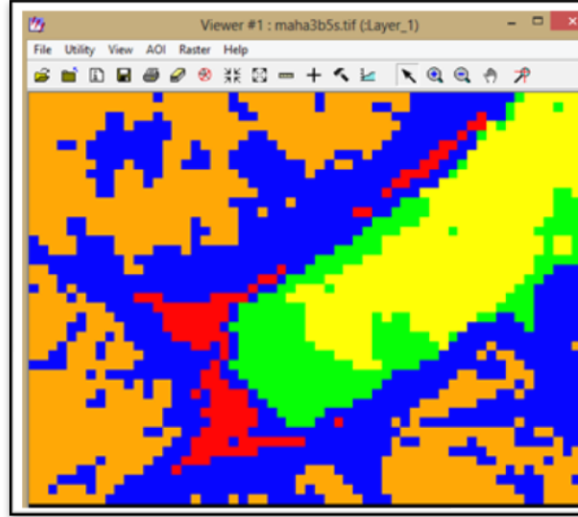
Şekil 5.37. Üç bant ve beş sınıf tahmini için Isodata sınıflandırma sonucu renkli görüntüsü



Şekil 5.38. Üç bant ve beş sınıf tahmini için yapılan ön bilgilendirme



Şekil 5.39. Üç bant ve beş sınıf tahmini için en kısa uzaklık sınıflandırma sonucu görüntüsü



Şekil 5.40. Üç bant ve beş sınıf tahmini için Mahalanobis uzaklık sınıflandırma sonucu görüntüsü

5.7. Modifiye EM Algoritmasının Üç Bantlı 15 Bileşenli Uzaktan Algılama Verisine Uygulanması

Elde edilen her bir sınıf ve banta ait ortalamalar, karma oranlar, varyans kovaryans matrisleri değerleri aşağıda verilmiştir:

Bileşen değerleri sırası ile

0.059399802642452	0.049897834981644	0.085589468892723
0.043264504543005	0.108855173141347	0.073368471261301
0.012132206465501	0.017234348746959	0.080765812664661
0.065853286510491	0.011874455558706	0.079607032753629
0.074025061459654	0.149531572296908	0.088600968081019

Her bir bileşene ait varyans-kovaryans matrisleri

Bileşen (:,:,1) =

1.0e+06 *

6.673505178771211	4.203689817869507	3.083133960865674
4.203689817869507	3.662112997466503	2.700391730209598
3.083133960865674	2.700391730209598	2.035674120315918

Bileşen (:,:,2) =

1.0e+05 *
0.030766834884940 -0.019776058771987 -0.083705449948721
-0.019776058771987 0.240471348318334 0.545363584652573
-0.083705449948721 0.545363584652573 1.337840717045214

Bileşen (:,:,3) =

1.0e+05 *
8.956538321263681 4.478888096777071 2.677279108868982
4.478888096777071 3.170081967876425 1.888374607512407
2.677279108868982 1.888374607512407 1.167864701133333

Bileşen (:,:,4) =

1.0e+06 *
1.141934962733821 0.440245525223899 0.254662849387024
0.440245525223899 0.204613018301913 0.118878992760400
0.254662849387024 0.118878992760400 0.072280837450508

Bileşen (:,:,5) =

1.0e+06 *
1.269507851990624 0.717596892632975 0.371196526292550
0.717596892632975 0.477152141833457 0.261569868571191
0.371196526292550 0.261569868571191 0.156334161338804

Bileşen (:,:,6) =

1.0e+05 *
9.747857251961188 6.122755551301946 3.667093389365415
6.122755551301946 7.606665602990575 4.801597093279044
3.667093389365415 4.801597093279044 3.163783698487425

Bileşen (:,:,7) =

1.0e+07 *
1.210841777647713 1.102812585209310 0.869985813424597

1.102812585209310 1.127966195046774 0.888547604936836

0.869985813424597 0.888547604936836 0.737166093688794

Bileşen (:,:,8) =

1.0e+05 *

0.639786151779665 0.216155131384475 -0.180229288688785

0.216155131384475 0.966839063158447 1.430770894964833

-0.180229288688785 1.430770894964833 2.756217232128020

Bileşen (:,:,9) =

1.0e+06 *

1.065735143845775 0.784825198582203 0.445210997646004

0.784825198582203 0.826824260469996 0.494003878902574

0.445210997646004 0.494003878902574 0.302039965493879

Bileşen (:,:,10) =

1.0e+05 *

6.630745940306873 3.096824866046426 1.795561337199627

3.096824866046426 1.622514193538249 0.952706088155087

1.795561337199627 0.952706088155087 0.597989363651350

Bileşen (:,:,11) =

1.0e+06 *

1.396954848047586 0.314979726351737 0.112614645811254

0.314979726351737 0.440335770533598 0.317987452976307

0.112614645811254 0.317987452976307 0.280378746189037

Bileşen (:,:,12) =

1.0e+07 *

1.042843794124156 0.611371753620534 0.439767224213253

0.611371753620534 0.422217482421089 0.318309529791930

0.439767224213253 0.318309529791930 0.248100985148838

Bileşen (:,:,13) =

1.0e+06 *

2.782226534466585	1.842483703191450	1.364879405177277
1.842483703191450	1.556683294996206	1.069586336574752
1.364879405177277	1.069586336574752	0.807571535750806

Bileşen (:,:,14) =

1.0e+06 *

2.555448535737900	1.519452638218601	0.954179753861475
1.519452638218601	1.081244669468079	0.700940897493540
0.954179753861475	0.700940897493540	0.500599297753166

Bileşen (:,:,15) =

1.0e+05 *

6.098766573584212	2.387656962919988	1.335566804541406
2.387656962919988	3.515976275865728	2.250340908875387
1.335566804541406	2.250340908875387	1.482746797565075

Bileşenlere ait ortalamalar:


1.0e+04 *

1.434911185761465	1.363642881654068	1.257367405663032
0.527077291926007	0.753864417500234	0.894425619195510
1.033778504689154	0.936252876297107	0.946753845206942
1.026694475540542	0.853640464625736	0.894428896344203
1.261679392356238	0.999952589980520	0.980554291387441
1.156599615305444	1.063418716801025	1.039184378717865
1.453247411915294	1.515335157919642	1.437885210366481
0.560204776524805	0.771640282516524	0.895877808725249
1.105965148836122	1.026643011933791	1.009642859859502
0.875897037070865	0.834603693215984	0.883859960851227

0.794449196449270 0.889927447167507 0.983058856000083
1.280165659091507 1.205752248401527 1.155136544884457
1.425733835007552 1.252489368970595 1.146452967032793
1.335525390735268 1.117904879777000 1.063725938559020
1.109813124297439 1.007130216049270 0.991713553840714

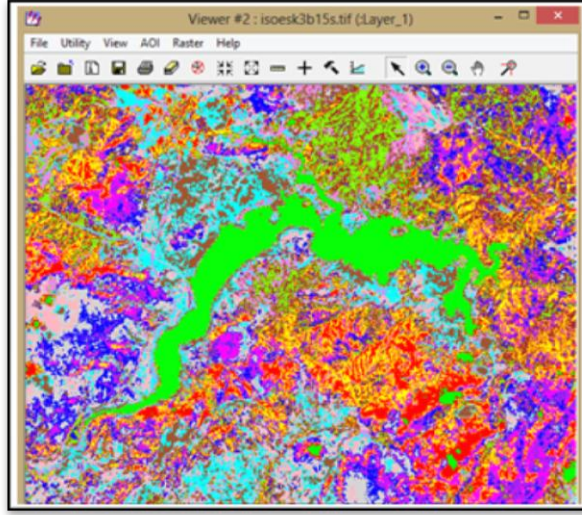
EM algoritması sonucu elde edilen parametre tahminleri ve karma model yardımı ile gerçekleştirilmiş olan sınıflandırma işlemi sonucunun görüntüsü Şekil (5.41)'de mevcuttur. Bu uygulamada tahmini sınıf yani bileşen sayısı 15 belirlenmiştir. EM algoritması modifiyesiz olarak çalıştırıldığında varyans kovaryans matrisi ya da matrislerinin tekillik tuzağına yakalandığı ve EM algoritmasını tamamlayamadığı görülmüş, düzenleme; 10^{-50} yani $1e-50$ hassaslığına getirildiğinde, algoritma tekillik tuzağından kurtularak yakınsamaya gitmiştir. Yani 10^{-50} hassaslığında düzenleme ('Regularize', $1e-50$) ile EM algoritması modifiye edilmiştir.

Şekil (5.42)'de ön bilgilendirmesiz Isodata sınıflandırma analizi sonucu görüntüsü, Şekil (5.43)'de yapılan ön bilgilendirmeye bağlı olarak en kısa uzaklık sınıflandırma analizi sonucu görüntüsü ve Şekil (5.44)'de yine yapılan ön bilgilendirmeye bağlı olarak en Mahalanobis uzaklık sınıflandırma analizi sonucu görüntüsü yer almaktadır.

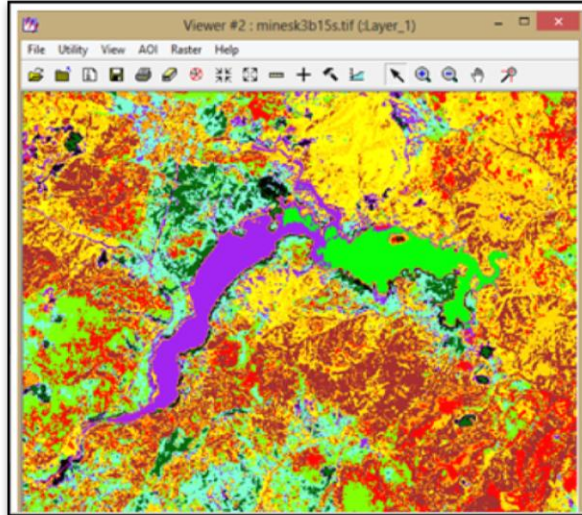


Şekil 5.41. Üç bant ve 15 sınıf tahmini için modifiye EM algoritması sonucu elde edilen parametre tahminleri ve karma model yardımı ile gerçekleştirilmiş olan sınıflandırma analizi sonucunun görüntüsü (matlab'dan elde edilen resim dosyasının erdas programında açılmış hali)

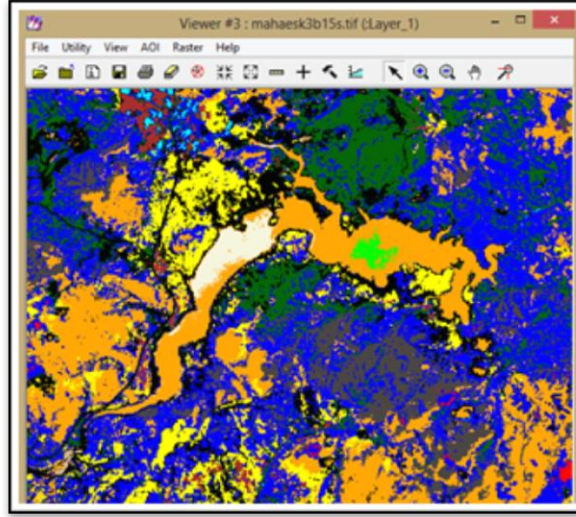
Aynı uzaktan algılama verisi için Isodata, en kısa uzaklık ve Mahalanobis uzaklık sonuçları aşağıda verilmiştir:



Şekil 5.42. Üç bant ve 15 sınıf tahmini için Isodata sınıflandırma sonucu



Şekil 5.43. Üç bant ve 15 sınıf tahmini için en kısa uzaklık sınıflandırma sonucu görüntüsü



Şekil 5.44. Üç bant ve 15 sınıf tahmini için Mahalanobis uzaklık sınıflandırma sonucu görüntüsü

5.8. Modifiye EM Algoritmasının Satürn Gezegeni Etrafındaki Halkalara Ait Uzaktan Algılama Verisine Uygulanması

Bu uygulamada tahmini sınıf yani bileşen sayısı 20 belirlenmiştir. EM algoritması modifiyesiz olarak çalıştırıldığında varyans kovaryans matrisi ya da matrislerinin tekillik tuzağına yakalandığı ve EM algoritmasını tamamlayamadığı görülmüş, 10^{-50} yani $1e-50$ hassaslığında düzenlendiğinde yani regularize edildiğinde varyans kovaryans matrisi ya da matrislerinin hala tekillik tuzağına yakalanmaya devam ettiği görülmüştür. Hassaslık değeri arttırılarak 10^{-5} yani $1e-5$ hassaslığına getirildiğinde algoritma tekillik tuzağından kurtularak yakınsamaya gitmiştir. Yani 10^{-5} hassaslığında düzenleme ('Regularize', $1e-5$) ile EM algoritması modifiye edilmiştir. Satürn gezegeni çevresine ait 20 bileşenli üç bantlı Gauss karma dağılıma ait elde edilen değerler ve elde edilen her bir sınıf ve banta ait ortalamalar, karma oranlar, varyans kovaryans matrisleri değerleri aşağıda mevcuttur:

Bileşen 1:

Karma oran: 0.095517

Ortalama: $1.0e+02$ *

1.558548954109960 1.435321887620107 1.012014179247081

Bileşen 2:

Karma oran: 0.069327

Ortalama: 1.0e+02 *

1.207165326923314 1.036833491622086 0.542482143078002

Bileşen 3:

Karma oran: 0.024158

Ortalama: 1.0e+02 *

1.752983391318435 1.941110230453257 1.692053578867351

Bileşen 4:

Karma oran: 0.039252

Ortalama: 1.0e+02 *

2.133625823050279 1.244160005459692 0.458793232011681

Bileşen 5:

Karma oran: 0.054694

Ortalama: 1.0e+02 *

2.295049064161958 2.009264987278734 1.529521772408351

Bileşen 6:

Karma oran: 0.033076

Ortalama: 22.516143405634786 25.467110851323227

18.794598275673192

Bileşen 7:

Karma oran: 0.013993

Ortalama: 1.0e+02 *

1.334806281427815 1.653780144701676 1.814542908515376

Bileşen 8:

Karma oran: 0.055745

Ortalama: 1.0e+02 *

0.962036925475505 1.020159609412636 0.799381384378788

Bileşen 9:

Karma oran: 0.062890

Ortalama: 2.358835810350218 5.065607165066840

7.115325588656789

Bileşen 10:

Karma oran: 0.193557

Ortalama: 0 3.786464669173419 6.589146600556385

Bileşen 11:

Karma oran: 0.046279

Ortalama: 11.633686643490318 40.546449999675360

63.636746425681245

Bileşen 12:

Karma oran: 0.070673

Ortalama: 10.440971996694717 12.991999116365466

10.687080320095873

Bileşen 13:

Karma oran: 0.016253

Ortalama: 1.0e+02 *

0 0.490013883413022 1.013055886164258

Bileşen 14:

Karma oran: 0.024407

Ortalama: 1.0e+02 *

1.034384143387019 1.425460197217821 1.052330419900952

Bileşen 15:

Karma oran: 0.009111

Ortalama: 1.0e+02 *

1.016736046097971 1.067253125903947 1.340847281936613

Bileşen 16:

Karma oran: 0.037847

Ortalama: 1.0e+02 *

2.431041849147935 2.336512247974828 2.136766773503577

Bileşen 17:

Karma oran: 0.033960

Ortalama: 35.902006108886155 77.487372472659757

87.314323773208287

Bileşen 18:

Karma oran: 0.027236

Ortalama: 60.619198447434123 51.106680980571511

25.867302781712208

Bileşen 19:

Karma oran: 0.059916

Ortalama: 1.0e+02 *

1.702077810658156 0.891197157610563 0.235091779199767

Bileşen 20:

Karma oran: 0.032110

Ortalama: 1.0e+02 *

0.414589565637279 1.096296924803774 1.008515669714081

Her bir bileşene ait varyans-kovaryans matrisleri

Bileşen (:,:,1) =

1.0e+03 *

1.510174193542151 0.488458858132945 -0.089621530850809

0.488458858132945 0.421861000427908 0.305822808956376

-0.089621530850809 0.305822808956376 0.612894461720613

Bileşen (:,:,2) =

1.0e+03 *
1.609651108661713 0.623039462511872 -0.035433305533024
0.623039462511872 0.544786855697932 0.201032678248100
-0.035433305533024 0.201032678248100 0.254690707252355

Bileşen (:,:,3) =

1.0e+03 *
1.267716577934034 0.583009136008644 0.273502815372085
0.583009136008644 0.310371634139240 0.185530127331675
0.273502815372085 0.185530127331675 0.193307238137644

Bileşen (:,:,4) =

1.0e+02 *
3.380888670707153 3.154981867790984 1.527778001657469
3.154981867790984 4.983264625951813 3.311889254085395
1.527778001657469 3.311889254085395 2.893725867854905

Bileşen (:,:,5) =

1.0e+03 *
0.210582761213690 0.088137529103203 -0.009146673936948
0.088137529103203 0.361833140727217 0.679994505843065
-0.009146673936948 0.679994505843065 1.563688055164408

Bileşen (:,:,6) =

1.0e+02 *
1.128864505108211 0.384925774481709 -0.362146372864912
0.384925774481709 0.363853239026173 0.092622799059211
-0.362146372864912 0.092622799059211 0.523884431304894

Bileşen (:,:,7) =

1.0e+03 *
3.315742128265478 2.134044525170941 1.553093405746442

2.134044525170941 1.480845673547179 1.081429607219394

1.553093405746442 1.081429607219394 0.867598132177884

Bileşen (:,:,8) =

1.0e+03 *

1.700658633662618 1.267230196189465 0.840155833846110

1.267230196189465 1.083749621679804 0.813972443212997

0.840155833846110 0.813972443212997 0.710314232947549

Bileşen (:,:,9) =

1.865632895336806 0.489187504821071 0.944706186099870

0.489187504821071 7.959652296262306 4.093046454104075

0.944706186099870 4.093046454104075 11.038664348736006

Bileşen (:,:,10) =

0.000010000000000 0 0

0 9.747954743997006 4.153023625164888

0 4.153023625164888 9.754880622255595

Bileşen (:,:,11) =

1.0e+02 *

0.475081603763743 -0.080294280496747 -1.036249039765664

-0.080294280496747 1.799371047352470 3.221129787188679

-1.036249039765664 3.221129787188679 8.300849832200480

Bileşen (:,:,12) =

27.249518721157923 16.209299299488105 10.018627525365464

16.209299299488105 31.761916998304667 15.343305552856039

10.018627525365464 15.343305552856039 19.618913345990869

Bileşen (:,:,13) =

1.0e+02 *

0.000000100000000 0 0

0 0.830653040248518 0.994432579464353

0 0.994432579464353 1.351975475031421

Bileşen (:,:,14) =

1.0e+02 *

8.718423824886274 4.746939718764699 1.148199599973772

4.746939718764699 3.548442660408863 2.378113384475563

1.148199599973772 2.378113384475563 3.778892681475368

Bileşen (:,:,15) =

1.0e+03 *

3.254313003787943 1.511656089538915 0.964883413522407

1.511656089538915 1.047332550985735 0.847093887240010

0.964883413522407 0.847093887240010 0.807392228196741

Bileşen (:,:,16) =

1.0e+02 *

0.317391402352658 0.279041691343777 0.546409497743956

0.279041691343777 0.498251630644988 1.020837855166011

0.546409497743956 1.020837855166011 2.417633092537548

Bileşen (:,:,17) =

1.0e+02 *

3.147284423684117 1.973949075598514 -0.807993914655935

1.973949075598514 4.133392085508872 3.239056706781058

-0.807993914655935 3.239056706781058 7.693994028757280

Bileşen (:,:,18) =

1.0e+02 *

7.417981663109362 2.881617553749936 -0.479128682634833

2.881617553749936 2.373327093579111 0.983101496703419

-0.479128682634833 0.983101496703419 1.365039208902731

Bileşen (:,:,19) =

1.0e+02 *

9.264659861457291	3.908494393622809	1.026441811105393
3.908494393622809	2.980093385706532	1.173624050187257
1.026441811105393	1.173624050187257	0.663036762070061

Bileşen (:,:,20) =

1.0e+02 *

1.856257432880568	1.286248132345347	0.299746392879273
1.286248132345347	1.445740173154940	1.159164460147629
0.299746392879273	1.159164460147629	2.070961066300184

Karma bileşen oranları:

0.095516523272108	0.069326568006515	0.024158167097410
0.039252141780181	0.054694447953937	0.033075786393137
0.013992647018668	0.055745381167389	0.062890028440309
0.193557327244203	0.046278597554132	0.070672645684360
0.016253317595649	0.024406842130834	0.009111125578897
0.037847128505198	0.033959829367384	0.027235627739917
0.059916183815110	0.032109683654664	

Her bir bileşenin ortalamaları :


1.0e+02 *

1.558548954109960	1.435321887620107	1.012014179247081
1.207165326923314	1.036833491622086	0.542482143078002
1.752983391318435	1.941110230453257	1.692053578867351
2.133625823050279	1.244160005459692	0.458793232011681
2.295049064161958	2.009264987278734	1.529521772408351
0.225161434056348	0.254671108513232	0.187945982756732
1.334806281427815	1.653780144701676	1.814542908515376
0.962036925475505	1.020159609412636	0.799381384378788
0.023588358103502	0.050656071650668	0.071153255886568

0	0.037864646691734	0.065891466005564
0.116336866434903	0.405464499996754	0.636367464256812
0.104409719966947	0.129919991163655	0.106870803200959
0	0.490013883413022	1.013055886164258
1.034384143387019	1.425460197217821	1.052330419900952
1.016736046097971	1.067253125903947	1.340847281936613
2.431041849147935	2.336512247974828	2.136766773503577
0.359020061088862	0.774873724726598	0.873143237732083
0.606191984474341	0.511066809805715	0.258673027817122
1.702077810658156	0.891197157610563	0.235091779199767
0.414589565637279	1.096296924803774	1.008515669714081

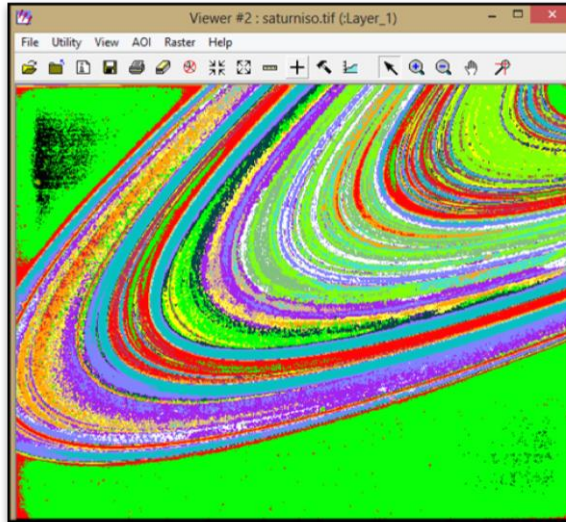
EM algoritması sonucu elde edilen parametre tahminleri ve karma model yardımı ile gerçekleştirilmiş olan sınıflandırma işlemi sonucunun görüntüsü Şekil (5.45)'de mevcuttur.

Şekil (5.46)'de ön bilgilendirmesiz Isodata sınıflandırma analizi sonucu görüntüsü, Şekil (5.47)'de yapılan ön bilgilendirmeye bağlı olarak en kısa uzaklık sınıflandırma analizi sonucu görüntüsü ve Şekil (5.48)'de yine yapılan ön bilgilendirmeye bağlı olarak en Mahalanobis uzaklık sınıflandırma analizi sonucu görüntüsü yer almaktadır.

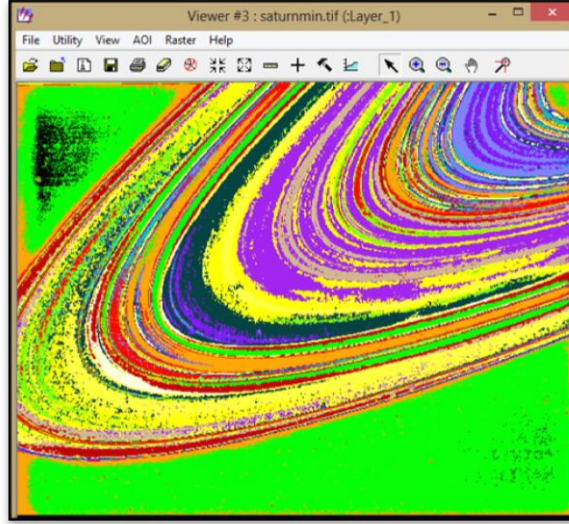


Şekil 5.45. Modifiye EM algoritması sonucu elde edilen parametre tahminleri ve karma model yardımı ile gerçekleştirilmiş olan analizi sonucunun görüntüsü (matlab'dan elde edilen resim dosyasının erdas programında açılmış hali)

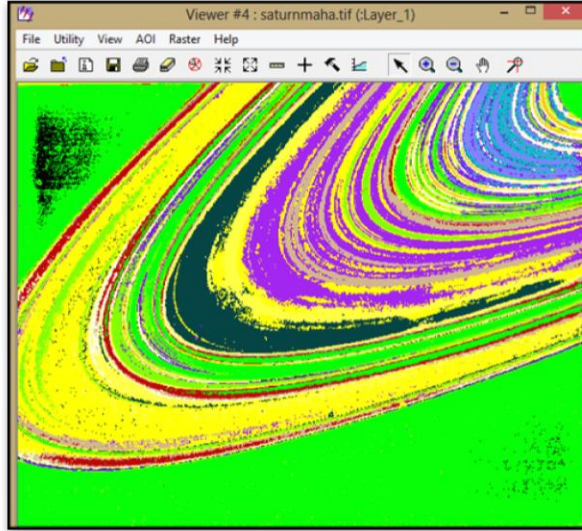
Aynı uzaktan algılama verisi için Isodata, en kısa uzaklık ve Mahalanobis uzaklık sonuçları aşağıda verilmiştir:



Şekil 5.46. Satürn gezegeni halkaları Isodata sınıflandırma sonucu



Şekil 5.47. Satürn gezegeni en kısa uzaklık sınıflandırma sonucu



Şekil 5.48. Satürn gezegeni Mahalanobis sınıflandırma sonucu

Bu sonuçlara göre EM algoritması yardımı ile elde edilen sınıflandırma analizi sonucunda bütün pikselleri doğru bir şekilde sınıflandırıldığı, diğer sınıflandırıcıların ise bazı pikselleri sınıflandırmadığı görülmektedir. Bu durumun nedeni olasılık yoğunluk fonksiyonunun almış olduğu değerlere göre sıralamaya yapmayan uzaklık esaslı sınıflandırıcıların bir piksel için ataması yapılacak sınıflardan iki ya da daha fazla eşit uzaklık değerine sahip olmasıdır. Böylece pikselin iki ya da daha fazla farklı sınıf için aynı uzaklık değerine sahip olmasından dolayı hangi sınıfa atanacağına karar verilemez.

5.9. EM Algoritmasının Jüpiter Gezegeni Atmosferi Uzaktan Algılama Verisine Uygulanması

Elde edilen her bir sınıf ve banta ait ortalamalar, karma oranlar, varyans kovaryans matrisleri değerleri aşağıda verilmiştir:

Bileşen 1:

Karma oran: 0.031105

Ortalama: 47.964508947938974 62.442603868505664
88.683919174194699

Bileşen 2:

Karma oran: 0.053385

Ortalama: 75.367356780000094 77.015869868843481
85.460928673019694

Bileşen 3:

Karma oran: 0.035934

Ortalama: 72.351395874699676 76.585901488726975
90.548197198261533

Bileşen 4:

Karma oran: 0.076403

Ortalama: 79.676345368067459 78.903233613485952
88.713792985025492

Bileşen 5:

Karma oran: 0.064481

Ortalama: 81.101464125901202 84.893029939119600
96.443416243654823

Bileşen 6:

Karma oran: 0.041898

Ortalama: 74.100258040736023 77.511920329953568
90.444925817803082

Bileşen 7:

Karma oran: 0.026210

Ortalama: 1.0e+02 *

0.496348273331653 0.782020356447820 1.102302609442211

Bileşen 8:

Karma oran: 0.059703

Ortalama: 79.263120772886438 80.720902599601075
89.131470547305469

Bileşen 9:

Karma oran: 0.012425

Ortalama: 8.576291237779136 33.508150191776167
77.728263148640636

Bileşen 10:

Karma oran: 0.108508

Ortalama: 1.0e+02 *

1.058654615805670 1.399111056520685 1.772173821838881

Bileşen 11:

Karma oran: 0.052339

Ortalama: 48.587930992234156 49.350962283256536
68.476782497670754

Bileşen 12:

Karma oran: 0.047863

Ortalama: 24.822965975625412 35.304809893323657
70.575334107023679

Bileşen 13:

Karma oran: 0.061789

Ortalama: 76.434429273204771 76.962627119692982
87.004754934176077

Bileşen 14:

Karma oran: 0.062395

Ortalama: 1.0e+02 *

1.115415397254455 1.300131292660108 1.538657014764043

Bileşen 15:

Karma oran: 0.044329

Ortalama: 35.553905524324215 52.756787113889914
82.446457534882882

Bileşen 16:

Karma oran: 0.050275

Ortalama: 46.624207623100759 53.315582069719355
72.348927549748524

Bileşen 17:

Karma oran: 0.045062

Ortalama: 1.0e+02 *

0.916036245582491 0.955189425848093 1.024625943852608

Bileşen 18:

Karma oran: 0.030225

Ortalama: 68.204841510505702 75.827463086842116
93.248183730532318

Bileşen 19:

Karma oran: 0.066806

Ortalama: 1.0e+02 *

1.073894384915057 1.111281148885294 1.140038631900281

Bileşen 20:

Karma oran: 0.028864

Ortalama: 1.0e+02 *

0.643853891187779 0.940282310463387 1.303054096292309

Her bir bileşene ait varyans-kovaryans matrisleri

Bileşen (:,:,1) =

1.0e+02 *

2.015486368716923 -0.247688957672851 -1.858679075953096

-0.247688957672851 0.791139413914082 1.338772382509042

-1.858679075953096 1.338772382509042 3.504230757170985

Bileşen (:,:,2) =

98.503738698496520 40.018060923638394 -1.700539647388507

40.018060923638394 26.972004884102919 24.310255438963019

-1.700539647388507 24.310255438963019 86.647239294601306

Bileşen (:,:,3) =

1.0e+02 *

2.134309307191774 1.977550936809461 1.340432488651000

1.977550936809461 2.632219843164898 2.628867371229591

1.340432488651000 2.628867371229591 3.497979308572141

Bileşen (:,:,4) =

1.0e+02 *

3.174711610846747 2.960490852110265 1.767114681302047

2.960490852110265 3.019338875900863 1.938834019609812

1.767114681302047 1.938834019609812 1.471583517639792

Bileşen (:,:,5) =

1.0e+02 *

1.946111728023575 1.852538650978403 0.891413789283687

1.852538650978403 2.264234259383453 1.426426168343189

0.891413789283687 1.426426168343189 1.325938786044160

Bileşen (:,:,6) =

1.0e+02 *

1.707453344066059 1.737592223123129 1.272154100211997

1.737592223123129 2.659390095043746 2.805637836987054

1.272154100211997 2.805637836987054 3.796319015112026

Bileşen (:,:,7) =

1.0e+02 *

1.062109570609703 -0.003153044921410 -0.897398103766562

-0.003153044921410 0.410171546193413 0.897616536111099

-0.897398103766562 0.897616536111099 2.898656230809404

Bileşen (:,:,8) =

1.0e+02 *

2.316211677237494 2.384378555260809 1.993827886390637

2.384378555260809 3.367448942873933 3.548476143043993

1.993827886390637 3.548476143043993 4.371381401292503

Bileşen (:,:,9) =

72.680004143843377 25.664924486582844 2.960473731691599

25.664924486582844 77.969774850624461 79.083651502097581

2.960473731691599 79.083651502097581 93.756646050640882

Bileşen (:,:,10) =

1.0e+02 *

1.014175451608223 0.888239084031903 0.457559513456717

0.888239084031903 1.044567964049988 0.831870874232081

0.457559513456717 0.831870874232081 1.165104234182777

Bileşen (:,:,11) =

1.0e+02 *

2.421737935054630 2.402912680682082 1.497920540433317

2.402912680682082 2.504261151654669 1.686092933375006

1.497920540433317 1.686092933375006 1.450499536017643

Bileşen (:,:,12) =

33.185018777000032 24.821548798151273 5.101674528162218

24.821548798151273 57.543337653938771 55.148204553061369

5.101674528162218 55.148204553061369 74.918576157001723

Bileşen (:,:,13) =

21.678619288371930 17.995518729642075 10.136515650659284

17.995518729642075 31.582297951568268 42.378098372496787

10.136515650659284 42.378098372496787 98.321400412839182

Bileşen (:,:,14) =

1.0e+02 *

1.352250249074641 1.107996195440607 0.356215999611785

1.107996195440607 1.755067413174728 1.882813305649455

0.356215999611785 1.882813305649455 3.411136162873269

Bileşen (:,:,15) =

1.0e+02 *

0.505975950527030 0.315237404806712 -0.074039059148540

0.315237404806712 0.676020378355372 0.636297371364724

-0.074039059148540 0.636297371364724 1.093832432275370

Bileşen (:,:,16) =

1.0e+02 *

1.077975142585041 1.145272158172635 0.609762495315045

1.145272158172635 1.593718897095945 1.328266316949475
0.609762495315045 1.328266316949475 1.807902762849844

Bileşen (:,:,17) =

1.0e+02 *

2.542147181988618 2.437553786076034 2.255877857335870
2.437553786076034 3.216756511212414 3.811198802299647
2.255877857335870 3.811198802299647 5.472967381033886

Bileşen (:,:,18) =

1.0e+02 *

5.580562200051888 3.726574769029820 0.874983552920429
3.726574769029820 2.903093057714198 1.170825742522299
0.874983552920429 1.170825742522299 1.091349915046591

Bileşen (:,:,19) =

1.0e+02 *

1.161559656899645 0.914046868593732 0.521459276532489
0.914046868593732 1.117296209497706 1.109967876038541
0.521459276532489 1.109967876038541 1.839244231837399

Bileşen (:,:,20) =

1.0e+02 *

1.700352495000890 0.888767200557240 0.101667942406421
0.888767200557240 1.229251907934069 1.516915344899956
0.101667942406421 1.516915344899956 3.045156427100238

Karma bileşen oranları:

0.031105433056040 0.053384648662507 0.035933903378090
0.076402628812084 0.064481201688316 0.041898274069678
0.026210402590837 0.059703442389058 0.012425072666423
0.108507842630487 0.052339065664482 0.047863271295504
0.061788665796580 0.062394841572033 0.044328794152201

0.050275328068056 0.045061773389284 0.030224819815725
0.066806497901760 0.028864092400857


Her bir bileşenin ortalamaları :

1.0e+02 *

0.479645089479390 0.624426038685057 0.886839191741947
0.753673567800001 0.770158698688435 0.854609286730197
0.723513958746997 0.765859014887270 0.905481971982615
0.796763453680675 0.789032336134860 0.887137929850255
0.811014641259012 0.848930299391196 0.964434162436548
0.741002580407360 0.775119203299536 0.904449258178031
0.496348273331653 0.782020356447820 1.102302609442211
0.792631207728864 0.807209025996011 0.891314705473055
0.085762912377791 0.335081501917762 0.777282631486406
1.058654615805670 1.399111056520685 1.772173821838881
0.485879309922342 0.493509622832565 0.684767824976708
0.248229659756254 0.353048098933237 0.705753341070237
0.764344292732048 0.769626271196930 0.870047549341761
1.115415397254455 1.300131292660108 1.538657014764043
0.355539055243242 0.527567871138899 0.824464575348829
0.466242076231008 0.533155820697194 0.723489275497485
0.916036245582491 0.955189425848093 1.024625943852608
0.682048415105057 0.758274630868421 0.932481837305323
1.073894384915057 1.111281148885294 1.140038631900281
0.643853891187779 0.940282310463387 1.303054096292309


EM algoritması sonucu elde edilen parametre tahminleri ve karma model yardımı ile gerçekleştirilmiş olan sınıflandırma işlemi sonucunun görüntüsü Şekil (5.49)'da mevcuttur. Şekil (5.50)'de ön bilgilendirmesiz Isodata sınıflandırma

analizi sonucu görüntüsü, Şekil (5.51)'de yapılan ön bilgilendirme ve Şekil (5.52)'de yapılan bu ön bilgilendirmeye bağlı olarak en kısa uzaklık sınıflandırma analizi sonucu görüntüsü ve Şekil (5.53)'de yine yapılan bu ön bilgilendirmeye bağlı olarak en Mahalanobis uzaklık sınıflandırma analizi sonucu görüntüsü yer almaktadır.




Şekil 5.49. EM algoritması sonucu elde edilen parametre tahminleri ve karma model yardımı ile gerçekleştirilmiş olan sınıflandırma analizi sonucunun görüntüsü (matlab'dan elde edilen resim dosyasının Erdas programında açılmış hali)


Bu sonuçlarda EM algoritması yardımı ile elde edilen görüntü analizi sonuçlarının iyi olduğu özellikle fırtına içlerinin sınıflandırmasını iyi yaptığı görülmektedir. Diğer sınıflandırıcılardan en kısa uzaklık sınıflandırıcısı EM algoritmasına yakın olarak sınıflandırma yapmıştır.




Şekil 5.50. Isodata sınıflandırma sonucu



Şekil 5.51. Yapılan ön bilgilendirme



Şekil 5.52. En kısa uzaklık sınıflandırma sonucu




Şekil 5.53. Mahalanobis uzaklık sınıflandırma sonucu

6. ARAŞTIRMA SONUÇLARI

Üç bant ve çeşitli tahmini sınıf sayılarına göre modifiyesiz ve modifiyeli EM algoritması yardımı ile elde edilen sınıflandırma sonuçları Isodata, en kısa uzaklık ve Mahalanobis uzaklık sınıflandırma sonuçları ile görsel olarak karşılaştırılmıştır.

6.1. Üç Bant ve İki Bileşenli Uzaktan Algılama Verisine Bağlı Sonuçlar

Tahmini sınıf sayısı iki olan üç bantlı uzaktan algılama verisi için aşağıdaki çeşitli sınıflandırma sonuçları elde edilir :

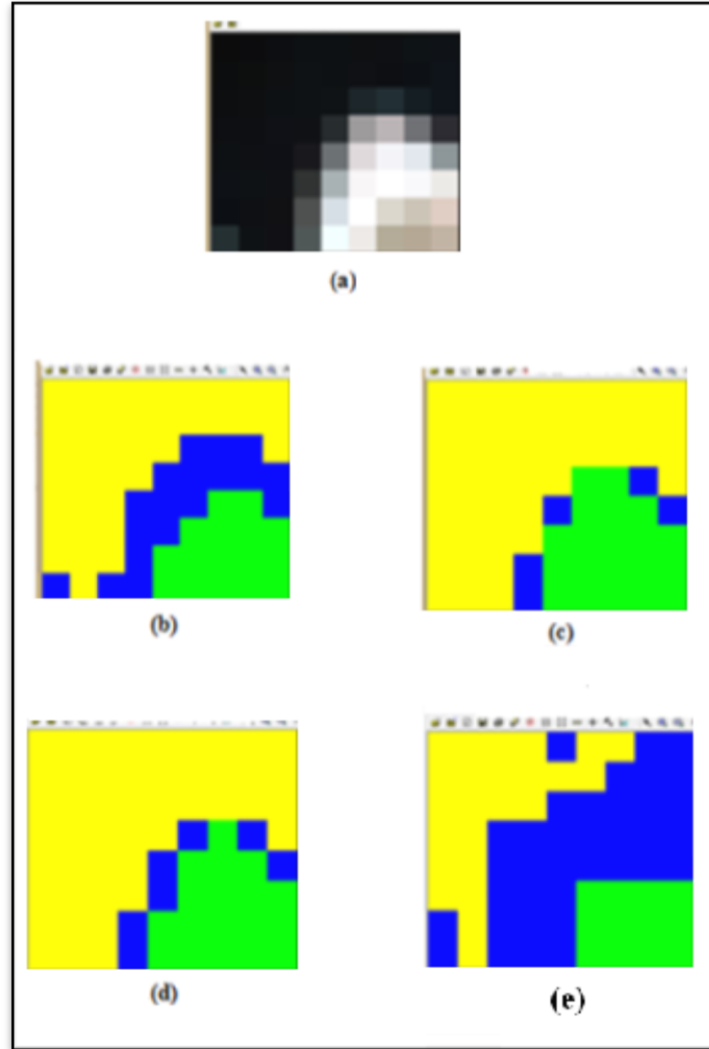


Şekil 6.1. Üç bant ve iki sınıf için sınıflandırma sonuçlarının karşılaştırmalı gösterimi, Orijinal veri (a), EM algoritması yardımı ile sınıflandırma sonucu (b), Isodata sınıflandırma sonucu (c), en kısa uzaklık sınıflandırma sonucu (d), Mahalanobis uzaklık sınıflandırma sonucu (e)

Şekil (6.1)'de orijinal uydu verisi ve sınıflandırma sonuçlarının karşılaştırılması görüntüsünden anlaşılacağı üzere modifiyesiz EM algoritması üç bantlı ve tahmini iki sınıflı uydu verisi için diğer sınıflandırıcılara göre daha doğru ve etkin sınıflandırma yapmıştır.

6.2. Üç Bant ve Üç Bileşenli Uzaktan Algılama Verisine Bağlı Sonuçlar

Tahmini sınıf sayısı üç olan üç bantlı uzaktan algılama verisi için aşağıdaki çeşitli sınıflandırma sonuçları elde edilir :

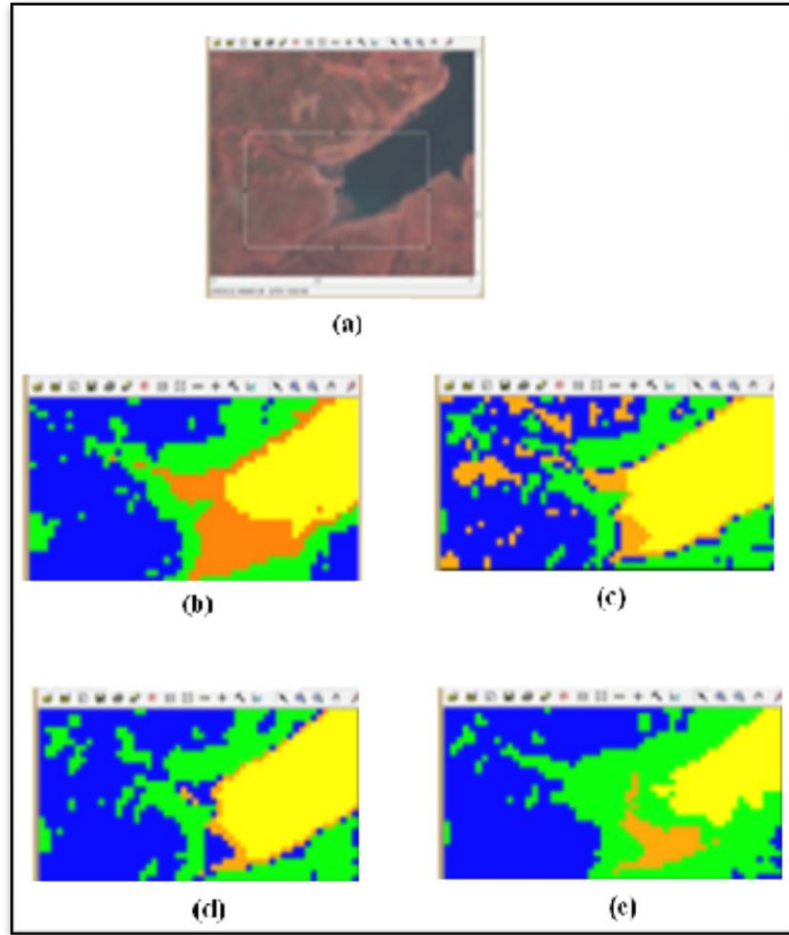


Şekil 6.2. Üç bant ve üç sınıf için sınıflandırma sonuçlarının karşılaştırmalı gösterimi Orijinal veri (a), EM algoritması yardımı ile sınıflandırma sonucu (b), Isodata sınıflandırma sonucu (c), en kısa uzaklık sınıflandırma sonucu (d), Mahalanobis uzaklık sınıflandırma sonucu (e)

Şekil (6.2)'de orijinal uydu verisi ve sınıflandırma sonuçlarının karşılaştırılması görüntüsünden anlaşılacağı üzere modifiyesiz EM algoritması yardımı ile üç bantlı ve tahmini üç sınıflı uydu verisi için yapılan sınıflandırma sonucu diğer sınıflandırıcılara göre daha doğru ve etkin sınıflandırma yapmıştır. Sınır piksellerini diğer sınıflandırıcılara göre daha gerçekçi olması dikkat çeken özelliğidir.

6.3. Üç Bant ve Dört Bileşenli Uzaktan Algılama Verisine Bağlı Sonuçlar

Tahmini sınıf sayısı dört olan üç bantlı uzaktan algılama verisi için aşağıdaki çeşitli sınıflandırma sonuçları elde edilir :

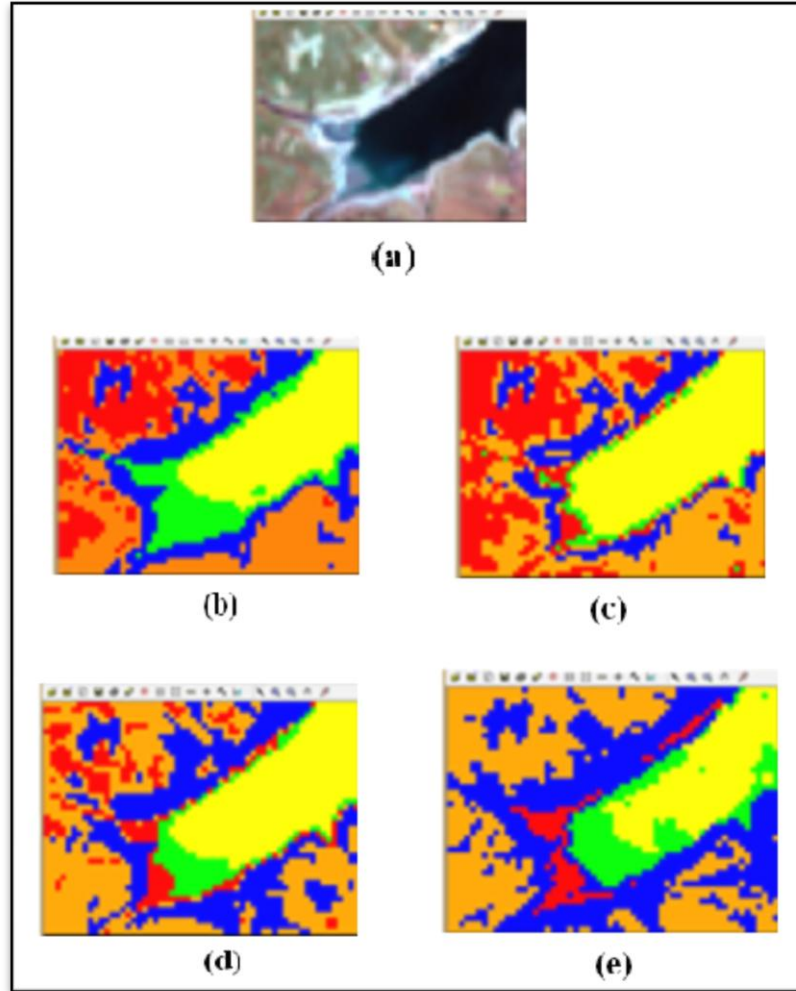


Şekil 6.3. Üç bant ve dört sınıf için sınıflandırma sonuçlarının karşılaştırmalı gösterimi
Orijinal veri (a), EM algoritması yardımı ile sınıflandırma sonucu (b), Isodata sınıflandırma sonucu (c), en kısa uzaklık sınıflandırma sonucu (d), Mahalanobis uzaklık sınıflandırma sonucu (e)

Şekil (6.3)'de orijinal uydu verisi ve sınıflandırma sonuçlarının karşılaştırılması görüntüsünden anlaşılacağı üzere modifiyesiz EM algoritması yardımı ile üç bantlı ve tahmini dört sınıflı uydu verisi için yapılan sınıflandırma sonucu, diğer sınıflandırıcılara göre daha doğru ve etkin sınıflandırma yapmıştır. Kıyı bölgeleri ve toprak bölgesinin diğer sınıflandırıcılara göre daha gerçekçi olması dikkat çekmektedir.

6.4. Üç Bant ve Beş Bileşenli Uzaktan Algılama Verisine Bağlı Sonuçlar

Tahmini sınıf sayısı beş olan üç bantlı uzaktan algılama verisi için aşağıdaki çeşitli sınıflandırma sonuçları elde edilir :

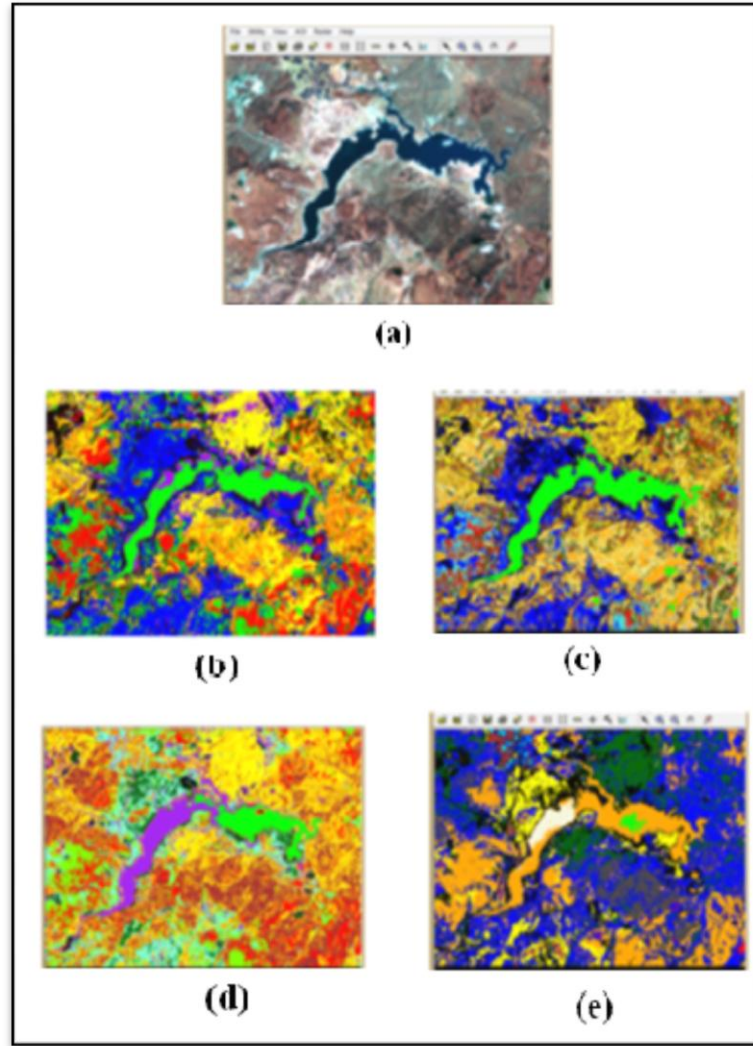


Şekil 6.4. Üç bant ve beş sınıf için sınıflandırma sonuçlarının karşılaştırmalı gösterimi Orijinal veri (a), EM algoritması yardımı ile sınıflandırma sonucu (b), Isodata sınıflandırma sonucu (c), en kısa uzaklık sınıflandırma sonucu (d), Mahalanobis uzaklık sınıflandırma sonucu (e)

Şekil (6.4)'de orijinal uydu verisi ve sınıflandırma sonuçlarının karşılaştırılması görüntüsünden anlaşılacağı üzere modifiyesiz EM algoritması yardımı ile üç bantlı ve tahmini beş sınıflı uydu verisi için yapılan sınıflandırma sonucu diğer sınıflandırıcılara göre daha doğru ve etkin sınıflandırma yapmıştır. Kıyı bölgelerindeki sığ su ve derin su ayrımı ile kıyı şeridini ve toprak düzenini diğer sınıflandırıcılara göre daha gerçekçi ayırt etmesi dikkat çekmektedir.

6.5. Üç Bant ve 15 Bileşenli Uzaktan Algılama Verisine Bağlı Sonuçlar

Tahmini sınıf sayısı 15 olan üç bantlı uzaktan algılama verisi için aşağıdaki çeşitli sınıflandırma sonuçları elde edilir :

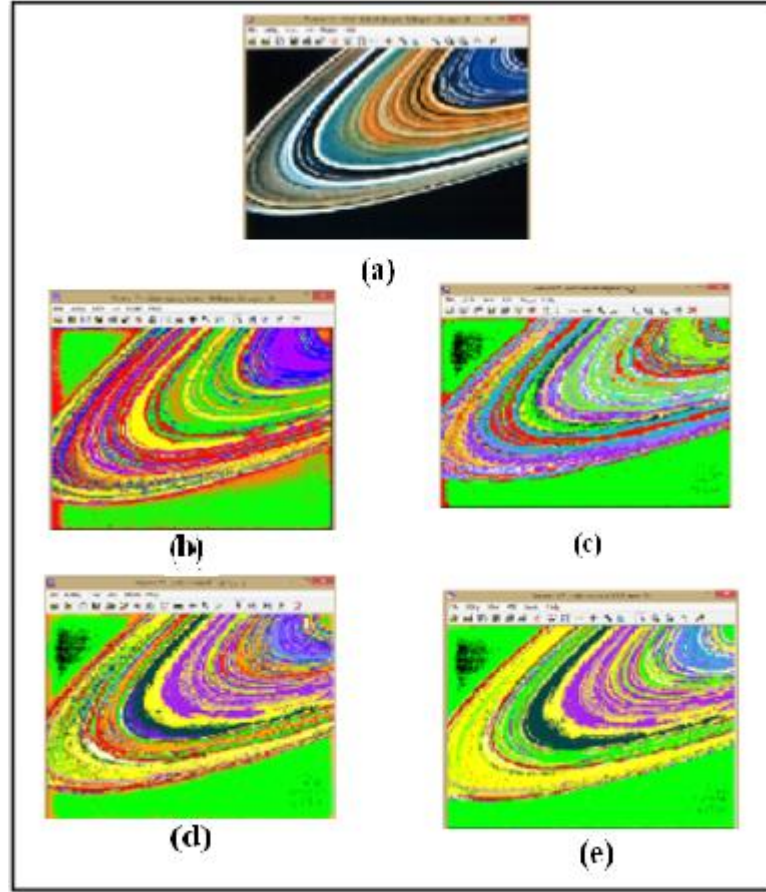


Şekil 6.5. Üç bant ve 15 sınıf için sınıflandırma sonuçlarının karşılaştırmalı gösterimi Orijinal veri (a), modifiye EM algoritması yardımı ile sınıflandırma sonucu (b), Isodata sınıflandırma sonucu (c), en kısa uzaklık sınıflandırma sonucu (d), Mahalanobis uzaklık sınıflandırma sonucu (e)

Şekil (6.5)'de orijinal uydu verisi ve sınıflandırma sonuçlarının karşılaştırılması görüntüsünden anlaşılacağı üzere modifiyeli EM algoritması üç bantlı ve tahmini 15 sınıflı uydu verisi için diğer sınıflandırıcılara göre daha doğru ve etkin sınıflandırma yapmıştır. Modifiye EM algoritmasının Porsuk Baraj göleti kıyı şeridinin ayrımını yapabirmiştir. Diğer sınıflandırıcılarda kıyı şeridinin ayrımının ya olmadığı ya da modifiye EM algoritması kadar gerçekçi olmadığı görülmektedir. Ayrıca derin ve sığ su ayrımını modifiye EM algoritması yardımı ile çok iyi yapılmış fakat diğer sınıflandırıcılar tarafından yapılamamıştır.

6.6. Satürn Halkaları Uzaktan Algılama Verisine Bağlı Sonuçlar

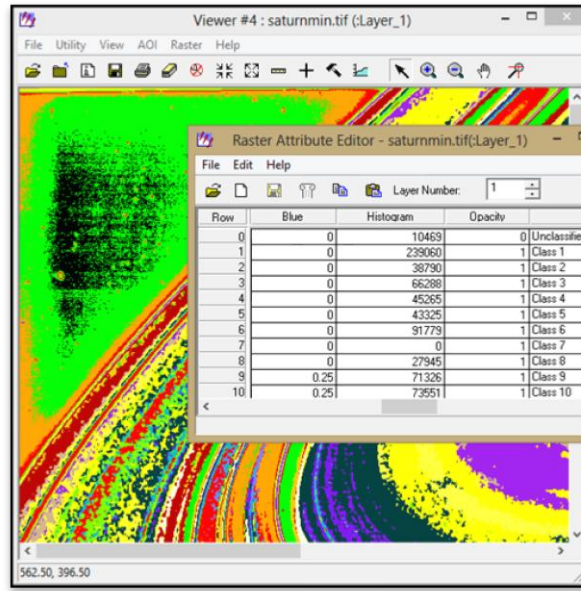
Tahmini sınıf sayısı 20 olan üç bantlı Satürn gezegeni halkalarına ait uzaktan algılama verisi için aşağıdaki çeşitli sınıflandırma sonuçları elde edilir :



Şekil 6.6. Satürn gezegeni halkaları sınıflandırma sonuçlarının karşılaştırmalı gösterimi Orijinal veri (a), Modifiye edilmiş EM algoritması yardımı ile sınıflandırma sonucu (b), Isodata sınıflandırma sonucu (c), en kısa uzaklık sınıflandırma sonucu (d), Mahalanobis uzaklık sınıflandırma sonucu (e)

Şekil (6.6)'da modifiye edilmiş EM algoritması yardımı ile elde edilen sınıflandırma sonucu görüntüsünün tüm pikselleri sınıflandırdığı ve bunu doğru bir şekilde yaptığı görülmektedir.

Buna karşın Isodata, en kısa uzaklık ve Mahalanobis uzaklık sınıflandırıcılarının bazı pikselleri sınıflandırmadıkları c, d ve e görüntü sonuçlarının sol üst ve sağ alt köşelerinde siyah renkli olarak gözükmekte ve erdas programının attribute editor kısmında sınıflandırma yapılamamış olarak belirtilmektedir (Şekil 6.7).

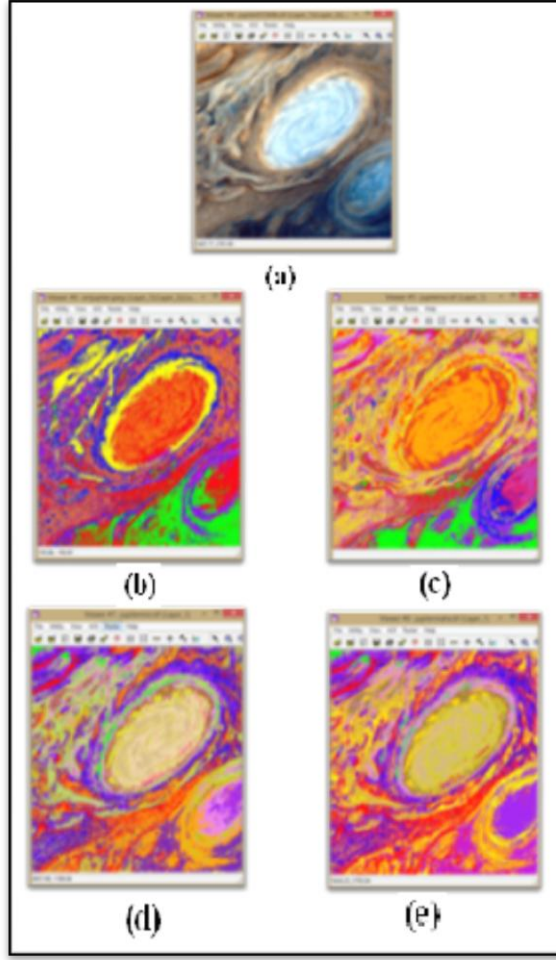


Şekil 6.7. En kısa uzaklık sınıflandırma tekniğinde bazı piksellerin sonuçları

6.7. Jüpiter Atmosferi Uzaktan Algılama Verisine Bağlı Sonuçlar

Tahmini sınıf sayısı 20 olan üç bantlı Jüpiter gezegeni atmosferik yapısı uzaktan algılama verisi için aşağıdaki çeşitli sınıflandırma sonuçları elde edilmiştir.

Şekil (6.7)'de EM algoritmasının Isodata, en kısa uzaklık ve Mahalanobis uzaklık sınıflandırıcılarına göre Jüpiter gezegeninin atmosferinde bulunan büyük ve küçük fırtınayı ve merkezini daha ayrıntılı sınıflandırdığı görülmektedir.



Şekil 6.8. Jüpiter gezegeni atmosferi sınıflandırma sonuçlarının karşılaştırmalı gösterimi Orijinal veri (a), EM algoritması yardımı ile sınıflandırma sonucu (b), Isodata sınıflandırma sonucu (c), en kısa uzaklık sınıflandırma sonucu (d),Mahalanobis uzaklık sınıflandırma sonucu (e)

Bu uzaktan algılama verisine ait sonuçlarda en kısa uzaklık sınıflandırma sonucu EM algoritması yardımı ile elde edilen sınıflandırma sonucuna yakın değerler almıştır.

EM algoritması yardımı ile elde edilen sınıflandırma sonucu büyük ve küçük fırtınaların içini diğer sınıflandırıcılara göre daha iyi sınıflandırırken uzaktan algılama verisinin sol üst tarafındaki girdaplar diğer sınıflandırıcıların sonuçlarında daha net gözükmemektedir. Tüm uzaktan algılama verileri ve pikselleri dikkate alındığında modifiyesiz ve modifiyeli EM algoritması yardımı ile elde edilen sonuçlarının karşılaştırması yapılan diğer sınıflandırıcıların sonuçlarına göre, görsel olarak daha az hatalı ve daha fazla güvenilir olduğu görülmektedir.

7. TARTIŞMA VE ÖNERİLER

Öncelikli olarak EM algoritmasının teorik yapısı ayrıntılı olarak incelendikten sonra tek boyutta yani tek bantta uygulaması geliştirilen matlab kodu ile sağlanmıştır. Daha sonra ise EM algoritması 3 boyutlu olarak 3 bant şeklinde uzaktan algılanmış uydu verilerine başarılı bir şekilde modifiyesiz olarak uygulanmıştır. Son olarak sınıf sayıları artırılmış 15 ve 20 sınıf için EM algoritması modifiyeli olarak başarılı bir şekilde uzaktan algılanmış uydu verisine uygulanmıştır.

Farklı uydu görüntü verilerinden, üç bant için tahmini olarak iki sınıf, üç sınıf, dört sınıf, beş sınıf ve 15 sınıfa sahip olan uydu verileri için modifiyesiz ya da modifiyeli EM algoritması yardımı ile elde edilen sınıflandırma sonuçları yanında Isodata, en kısa uzaklık ve Mahalanobis uzaklık sınıflandırma teknikleri ile karşılaştırılmıştır.

Bölüm 6'da ayrı ayrı kategoriler için bu dört sınıflandırma tekniği birbiri ile karşılaştırılmış ve EM algoritması yardımı ile elde edilen sınıflandırma sonuçlarının daha doğru ve gerçekçi olduğu gözlemlenmiştir.

Yapılan karşılaştırmalar Giriş bölümündeki hipoteze uygun olarak, olasılık bazlı ve olasılık bazlı olmayan şeklinde yapılmıştır. Daha ayrıntılı olarak açıklanmak gerekirse; EM algoritmasının modifiyesiz ve modifiyeli biçimi 2. Bölümde ayrıntılı olarak açıklandığı üzere sınıflandırma analizini parametre tahminleri ile elde edilen olasılık dağılımları ile yapar. Isodata, en kısa uzaklık ve Mahalanobis uzaklık sınıflandırma teknikleri ise olasılık dağılımları ile değil uzaklık ölçütünü temel alarak sınıflandırma yaparlar

Bunun yanında arazi kontrolü yapılmamasının nedeni, EM algoritmasının modifiyeli ve modifiyesiz biçiminin yalnızca ulaşılabilen yer ve konumlar için değil ulaşılabilen konumlar için de bilgi edinilmek için yapıyor olmasıdır. Örneğin gidilmesi şu an için olası olmayan uzak gezegenler hakkında bilgi edinilmek istenildiğinde arazi kontrolü yapmak şu an için imkansızdır. Bunun yanında benzer şekilde mikro biyolojide ve mikroskop altında yapılan araştırmalarda konum kontrolü yapılaz ya da yapılması çok zordur. Bunun gibi örnekler çoğaltılabilir.

Bu tezde modifiye bir teknik kullanılarak 3 bantlı ve çok bileşenli algılama verisine modifiye edilmiş EM algoritması başarılı bir şekilde uygulanmıştır. Başarılı olduğu porsuk baraj göleti çevresinde yapılan sınıflandırma için kıyı, göletin içindeki derinlik farklılıkları ve yol gibi sınıfları ayırt etmesinden belli olmaktadır. Örneğin aynı veri için Isodata sınıflandırma, en kısa uzaklık ve Mahalanobis uzaklık sınıflandırma tekniği uygulandığında bahsedilen ayrıntıları ayırt edememiştir. Bu durum daha açılırsa; Porsuk baraj göletindeki sığ su ve derin su ayrımı modifiye edilmiş EM algoritması yardımı ile elde edilmiş sınıflandırma sonuç görüntüsüne göre çok doğru ve gerçekçi bir şekilde yapılmış fakat Isodata sınıflandırma, en kısa uzaklık ve Mahalanobis uzaklık sınıflandırma tekniği sonuçlarının sığ ve derin su ayrımını yapamadıkları gözlemlenmiştir.

Bu duruma ilave olarak güneş sistemimizde bulunan Satürn gezegeni halkaları verisine yapılan sınıflandırma sonuçları karşılaştırmalarında modifiye edilmiş EM algoritması görsel olarak başarılı sonuç alıp tüm pikselleri sınıflandırmıştır. Buna karşın Isodata, en kısa uzaklık ve Mahalanobis uzaklık sınıflandırıcılarının modifiye edilmiş EM algoritması kadar başarılı sınıflandırma yapamadıkları gibi bazı pikselleri sınıflandırmadıkları görülmüştür.

Modifiye EM algoritmasında girilen ilk değerler uydu verisinin radyometrik çözünürlük sınırları içerisinde olmak zorundadır. Yani ilgili veri için radyometrik değerlerin en az değerinden daha az en fazla değerinden daha fazla değer ile giriş yapılamaz. Yapılsa bile mevcut veri aralığının dışında yapılacağı için zaten hedef harici ilk değer girişi yapılmış olunur.

Çok bantlı ve çok sınıflı uydu görüntü verisini sınıflandırması analizi tahmini sınıf sayısının girilmesinden sonraki adımda k-ortalamlar tekniği otomatik olarak yapılmıştır. Matlab’da bulunan “gmdistribution.fit” komutu geliştirilen kod içerisinde bulunan uzaktan algılama verisini kullanır. Bu veri ile ilgili tahmini sınıf sayısının girilmesinin ardından “gmdistribution.fit” komutu ile k-ortalamlar tekniği otomatik devreye girer ve ilk parametre tahminlerini yapar. k-ortalamlar tekniği uzaktan algılama verisini kullanacağı için k-ortalamlar tekniğinin kullandığı veriler uzaktan algılama verisinin radyometrik çözünürlük sınırları içerisinde dir. Bu durum EM algoritmasında var olabilecek ilk parametre tahmin değerlerinden kötü yönde etkilenmesi sorununu azaltır.

EM algoritması modifiye edilerek, varyans kovaryans değerlerinin yinelemeler sırasında, bir sonraki adımda işlem yapmasına engel olan tekillik sorunu durumundan kaçınılması süreci modifiye müdahale ile başarılı bir şekilde uygulanıp uzaktan algılama verisi sınıflandırılmış ve sınıflandırılmış sonuç görüntüye dönüştürülmüştür.

Mevcut uzaktan algılama paket programlarında EM algoritması yardımı ile sınıflandırma seçeneği bulunmamaktadır. Bu tez modifiyesiz ya da modifiyeli EM algoritmasını uzaktan algılanmış çoklu bant sisteminde çok sınıflı uydu görüntü verisine uygulamıştır.

EM algoritması az bileşeni olan uydu görüntü verileri sınıflarında hiçbir modifikasyona gerek kalınmadan düzgün çalışarak sınıflandırma işlemini gerçekleştirdiği gözlemlenirken alanın genişlemesi ve bileşen sayısının artması durumlarının bazılarında EM algoritması modifiye müdahaleye ihtiyaç duymuştur. Bu modifiye müdahale sonucunda ise karşılaştırması yapılan diğer üç teknikten daha doğru ve daha etkin bir biçimde başarılı sınıflandırma yapmıştır.

Ayrıca geliştirilen matlab kodu ile sınıflandırılmış her bir piksel ASCII formatında kayıt edilmiştir. Bunun yanında sınıflandırılan görüntülerde jpeg ve tiff formatlarında kayıt edilebilmiştir. Dolayısı ile EM algoritması çeşitli olası duruma uygun, kullanışlı ve esnek duruma getirilmiştir.

Çalışma sonucunda EM algoritması yardımı ile elde edilen sınıflandırma analizi sonuçlarının diğer üç sınıflandırıcı sonuçlarına göre daha güvenilir olduğunu yol, kıyı deniz, kara, sığ ve derin su gibi yer gerçeği sınıfları ile güneş sistemindeki gezegenler ait halka uzay boşluğu ve atmosfer içeriği sınıflarını karşılaştırılması yapılan diğer sınıflandırıcılara göre daha büyük bir doğrulukta gerçekçi dolayısı ile daha iyi sınıflandırmasından anlaşılmaktadır.

Böylece bu teze ait olan; modifiyesiz ve modifiyeli EM algoritması yardımı ile elde edilen parametre tahminleri ve karma model yardımı ile gerçekleştirilmiş olan sınıflandırma analizleri sonuçları, popüler ön bilgilendirmesiz ve ön bilgilendirmeli uzaklık esaslı sınıflandırıcılardan olan; Isodata, en kısa uzaklık ve Mahalanobis uzaklık sınıflandırma analizlerinden daha doğru sınıflandırma yapması yani daha güvenilir olması ile daha etkin olması hipotezi doğrulanmıştır.

Ayrıca bu tezin amacı olan ön bilgilendirmesiz ve ön bilgilendirmeli uzaklık esaslı ve olasılık dağılımı kullanmayan sınıflandırıcılara göre büyük bir

güvenilirlik ile daha etkin ve güvenilir sonuçlara ulaşmayı sağlayacak, istatistiksel öğrenme temelli modifiye bir yeni sınıflandırıcı geliştirmek amacı ile özellikle uzaktan algılamada sınıflandırma çalışması için ön bilgilendirmeli (kontrollü) sınıflamanın mümkün olmadığı, geçmiş tarihli görüntülerin sınıflanması, uzay gözlemlerine dayalı yapılacak sınıflandırmalar gibi durumlarda kullanılacak ön bilgilendirmeli sınıflandırma tekniklerine en yakın ve hatta daha güvenilir sonuca ulaşılmasını sağlayacak istatistiksel öğrenme tabanlı modifiye bir sınıflandırıcı geliştirilmesi amacı gerçekleştirilmiştir.

KAYNAKLAR

- Anonim , Center for International Earth Science Information Network, Earth Institute, Columbia University, <http://www.ciesin.org/TG/RS/satremot.html>, 2014a
- Anonim , “Fundamentals of Remote Sensing”, A Canada, Centre for Remote Sensing, Remote Sensing Tutorial, Canada, 2014b
- Anonim, “Erdas Field Guide, Fifth Edition, Revised and Expanded”, Erdas Inc., Atlanta, Georgia, USA, 1999, p: 15 -251
- Anonim, “Jupiter from the Ground”, 2011, <http://www.nasa.gov>
- Anonim, “ Composition Differences within Saturn's Rings”, 1981, <http://www.nasa.gov>
- Anonim, “Jupiter's Great Red Spot “1998, <http://www.nasa.gov>
- Anonim,” Plume from Dukono Volcano, Indonesia”, 2014, <http://www.nasa.gov>
- Anson R.W. and Ormeling F.J. (1993), “Basic Cartography-for students and technicians”, Elsevier, Vol 1.
- Archambeau C., Lee J.A. ve Verleysen M., “On Convergence Problems of the EM Algorithm for Finite Gaussian Mixtures” , *ESANN'2003 proceedings - European Symposium on Artificial Neural Networks*, Bruges (Belgium), pp. 99-106, 2003
- Bakker W.H., Feringa W., Gieske A. S. M., Gorte B.G.H., Grabmaier K.A., Hecker C.A., Horn J.A., Huurneman G.C., Janssen L.L.F., Kerle N., Meer F.D. v.d., Parodi G. N., Pohl C., Reeves C.V., Ruitenbeek F. J. v., Schetselaar E. M., Tempfli K., Weir M.J.C., Westinga E., Woldai T. “Principles of Remote Sensing, An introductory” (Ed: Tempfli K., Kerle N., Huurneman G.C., Janssen L.L.F.), The International Institute for Geo-Information Science and Earth Observation (ITC), pp: 97-103, Hollanda, 2009
- Bilmes J.A.,” A Gentle Tutorial of the EM Algorithm and its Application to Parameter Estimation for Gaussian Mixture and Hidden Markov Models”, 1998 <http://crow.ee.washington.edu/people/bulyko/papers/em.pdf>
- Bordes L, Chauveau D. ve Vandekerkhove P.,” An EM algorithm for a semiparametric mixture model”, *Universit´e de Marne-la-Vall´ee & CNRS*, 2006

- Chang S. C. ve Kim H. J.,” EM Algorithm”, Aralık 9, 2007
http://homepage.stat.uiowa.edu/~kcowles/s166_2007/chang166.pdf
- Campbell J.B. and Wynne R.H., “Introduction to Remote Sensing”, A Division of Guilford Publications, Inc., New York., 2011
- Conover W.J., “Practical Nonparametric Statistics, Third Edition “, (Ed: Wiley II O’Sullivan M., Perea J.), John Wiley & Sons, Inc. New York, A.B.D., pp. 115- 116, 1999.
- CORTÉS L.A.G, ve SORENSEN D.,” Alternative implementations of Monte Carlo EM algorithms for likelihood inferences”. *INRA, EDP Sciences, Genet. Sel. Evol.* 3., 443-452, 2001
- DOUCET A., GODSILL S. J. ve ROBERT C. P., “Marginal maximum a posteriori estimation using Markov chain Monte Carlo”, Kluwer Academic Publishers., *Statistics and Computing* 12, 77–84, 2002
- Eches O., Dobigeon N., Mailhes C. ve Tourneret J.-Y. , “UNMIXING HYPERSPECTRAL IMAGES USING A NORMAL COMPOSITIONAL MODEL AND MCMC METHODS”, *Statistical Signal Processing, 2009. SSP '09. IEEE/SP 15th Workshop on*, 978-1-4244-2711-6, Cardiff, 646 – 649, 2009
- Gelman A., Carlin J.B., Stren H.S., Rubin D.B. “Bayesian Data Analysis, Second Edition” (Ed: Chatfield C., Tanner M., Zidek J.), Chapman & Hall/CRC, A.B.D. pp. (6-7), 2004
- Han J., Kamber M. “Data Mining Concept and Techniques, Second Edition”, (Ed: Gray J., Stephan A.), Morgan Kaufmann publications, San Francisco, ABD., pp (5,659), 2006.
- Hestie T., Tibshirani R., Friedman J. (2008), *The Elements of Statistical Learning, Data Mining, Inference, and Prediction, Second Edition*, Springer, Stanford, California, A.B.D.
- Khorram S., Koch F. H., Van Der Wiele C.F., Nealson S.A.C. (2012), “Remote Sensing”, Springer, USA
- Kirshner S, Cadez I. V., Smyth P. ve , Kamath C., “Learning to Classify Galaxy Shapes Using the EM Algorithm”, *Advances in Neural Information Processing Systems 15, NIPS. 2002*, MIT Press, 2003.

- Kollu R., Rayapudi S. R., Narasimham SVL. ve Pakkurthi K M., “Mixture probability distribution functions to model wind speed distributions”, Kollu et al. *International Journal of Energy and Environmental Engineering*,3:27, 2010
- Korting T.S. , Dutra L. V. , Fonseca L.M.G ve Erthal G. J.,” Assessment of a modified version of the EM algorithm for remote sensing data classification”, *Image Processing Division, INPE, Sao Jos_e dos Campos*, 2004
- Köhl M., Magnussen S.S., Marchetti M. (2006), “Sampling Methods Remote Sensing and GIS Multiresource Forest Inventory”, Springer, Verlag Berlin Heidelberg New York, Tropical Forestry p:212,214
- Lasaponara R., Masini N. (2012), “ Satellite Remote Sensing”, Springer, Springer Dordrecht Heidelberg London New York, Volume 16, A New Tool for Archaeology
- Lei Y.H., Huan P. J., BaiRu X. ve Xuan Z. D.” An improved EM algorithm for remote sensing classification”. *Chinese Science Bulletin*, Vol.58 No.9: 1060-1071, 2013
- LEVINE R. ve CASELLA G. ,” Implementations of the Monte Carlo EM Algorithm”, *American Statistical Association, Institute of Mathematical Statistics, and Interface Foundation of North America Journal of Computational and Graphical Statistics*, Volume 10, Number 3, 422–439, 2001
- L. Gomez-Chova, J. Calpe, G. Camps-Valls, J.D. Martín, E. Soria, J. Vila, L. Alonso-Chorda, J. Moreno, “Semi-Supervised Classification Method For Hyperspectral Remote Sensing Images”, *IEEE*, 0-7803-7930-6, 2003
- Mantero P., Moser G., ve Serpico S.B., “Partially Supervised Classification of Remote Sensing Images Through SVM-Based Probability Density Estimation”, *IEEE TRANSACTIONS ON GEOSCIENCE AND REMOTE SENSING*, VOL. 43, NO. 3, p:559-570, 2005
- Li H., Zhang K. ve Jiang T.,” The Regularized EM Algorithm”, In *Proceedings of the 20th National Conference on Artificial Intelligence*, Pittsburgh, PA, A.B.D., 807 – 812, 2005
- McLachlan G. J., Krishnan T. “ The EM Algorithm and Extensions, Second Edition” (Ed: Balding D.J., Cressie N.A.C., Fitzmaurice G.M., Johnstone

- I.M., Molenberghs G., Scott D.W., Smith A.F.M., Tsay R.S., Weisberg S., Barnett V., Hunter S. Kendall D.G., Teugels J.L.), John Wiley & Sons, Inc., Hoboken, New Jersey, A.B.D., pp (1-3), 2008
- McLachan G.J. ve Peel D. “ Computing Issues for the EM Algorithm in Mixture Models” In *Computing Science and Statistics* Vol. 31, pp. 421-430, 1999.
- Mohamed R.M. ve Farag A.A., “A NEW UNSUPERVISED APPROACH FOR THE CLASSIFICATION OF MULTISPECTRAL DATA”, *ISIF*, p: 951-958, 2003.
- Mola E., *Kümeleme ve Çoklu Karesel Ayırma Çözümleme Teknikleri ve Uzaktan Algılanmış Uydu Verisi Yardımıyla Eskişehir/Kırka Çevresinde Bor Madeni Araştırılması*, Yüksek Lisans Tezi, Eskişehir Osmangazi Üniversitesi, Fen Bilimleri Enstitüsü, Eskişehir, 2005
- Myers W.L. and Patil G.P. (2006), “Pattern-Based Compression of Multi-Band Image Data for Landscape Analysis”, Springer, New York, USA, Environmental and Ecological Statistics Series: Volume 2
- Naim I. ve Gildea D. , “Convergence of the EM Algorithm for Gaussian Mixtures with Unbalanced Mixing Coefficients” *Appearing in Proceedings of the 29 th International Conference on Machine Learning, Edinburgh, Scotland, UK, 2012.*
- Nava F.P., Nava A P, Lamolda J.M.G. ve Redondo M. F., “*Change detection in remote sensing images with graph cuts*”, Programa para la Realización de Proyectos de Investigación ”,(Project PI 2002/186), 2002.
- Nityasuddhi D.,Böhning D.” Asymptotic properties of the EM algorithm estimate for normal mixture models with component specific variances”, *Elsevier Science B.V., Computational Statistics & Data Analysis*, 41, 591 – 601, 2003.
- Nowak R.D.,”Distributed EM Algorithms for Density Estimation and Clustering in Sensor Networks”, *Signal Processing, IEEE Transactions on* Volume: 51 , Issue: 8, p: 2245 – 2253, 2003.
- Paalanen P., “Bayesian Classification Using Gaussian Mixture Model and EM Estimation: Implementations and Comparisons”, 2004, <http://www.it.lut.fi/project/gmmbayes/downloads/doc/report04.pdf>

- Pal S.K. , ve Mitra P. , “Multispectral Image Segmentation Using the Rough-Set-Initialized EM Algorithm”, *IEEE TRANSACTIONS ON GEOSCIENCE AND REMOTE SENSING*, VOL. 40, NO. 11, p:2495-2501, 2002.
- Pernkopf F ve Bouchaffra D., “Genetic-Based EM Algorithm for Learning Gaussian Mixture Models”, *IEEE TRANSACTIONS ON PATTERN ANALYSIS AND MACHINE INTELLIGENCE*, VOL. 27, NO. 8, 1344-1348, 2005.
- Pernkopf F., “ON INITIALIZATION OF GAUSSIAN MIXTURES: A HYBRID GENETIC EM ALGORITHM”, *IEEE, ICASSP*, I-693 , I-696, 2005.
- Portugaly Y. “The maps hidden from the eye”, (1996), pp. 44-47
<http://geography.huji.ac.il/personal/Noam%20Levin/1999-fundamentals-of-remote-sensing.pdf>
- Rashed T. and Jürgens C. (2010), " Remote Sensing of Urban and Suburban Areas", Springer, New York, USA, Remote Sensing and Digital Image Processing
- Richards J.W., Hardin J., Grosfils E. B., “Weighted Model-Based Clustering for Remote Sensing Image Analysis” , *Computational Geosciences*, 14: 125-136; 2010.
- Robinson J.A., Amsbury D.L., Liddle D. A. ve Evans C.A., “Astronaut-acquired orbital photographs as digital data for remote sensing: spatial resolution”, *Int. J. Remote Sensing*, 23, 4403-4438, 2002.
- Rohatgi V.K., Saleh A.K.MD.E. “An Introduction to probability and Statistics, Second Edition, International Student Edition” (Ed: Cressie N.A.C., Fisher N.I., Johnstone I.M., Kadane J.B., Scott D.W., Silverman B.W., Smith A.F.M., Teugels J.L., Barnett V., Bradley R.A., Hunter J.S., Kendall D.G.), John Wiley & Sons, Inc. , Birleşik Krallık (Büyük Britanya), pp. (28-31,410-411, 426-428, (520-524), 2009.
- Russell S., Norvig P. “ Artificial Intelligence, A Modern Approach, Third Edition” (Ed: 1. Horton M., Hirsch M., Dunkelberger T., Haggerty M., Michael A., Disanno S., Bonnell I., Nohr M.L., Dulles G., Sandin D.), Pearson Education, Inc., New Jersey, A.B.D. pp. (1-2,39,59,243), 2010.
- Roweis S.,” EM Algorithms for PCA and SPCA”, 1998
<https://www.cs.nyu.edu/~roweis/papers/empca.pdf>,

- Schott J.R., (2007), “Remote Sensing, The Image Chain Approach”, Oxford University Press, Inc., New York, USA , 2 nd Edition textbook”, ITC, Enschede, The Netherlands, Fourth Edition
- THIESSON B., MEEK C. ve HECKERMAN D.,” Accelerating EM for Large Databases”, *Kluwer Academic Publishers., Machine Learning*, 45, 279–299, 2001.
- Tyagi M., Bovolo F., Mehra A.K., Chaudhuri S. ve Bruzzone L., A “Context-Sensitive Clustering Technique Based on Graph-Cut Initialization and Expectation-Maximization Algorithm”, *IEEE GEOSCIENCE AND REMOTE SENSING LETTERS*, VOL. 5, 21-25, 2008.
- Vlassis N. ve Likas A. “A Greedy EM Algorithm for Gaussian Mixture Learning”, *Kluwer Academic Publishers., Neural Processing Letters* 15: 77-87, 2002.
- Wang S. ,*Gaussian Mixture Model by Using EM*, 2004,
<http://www.stat.wisc.edu/~mchung/teaching/stat992/lec33.pdf>
- Weng Q., (2010), “Remote Sensing and GIS Integration Theories, Methods and Applications”, The McGraw-Hill Companies, Inc. , USA
- Xiong J. “Essential Bioinformatics” (Ed: Halliday K.), Cambridge University Press, New York, A.B.D. pp. (4,275), 2006.
- Yuille A. L., Stolorz P. ve Utans J.” Statistical Physics, Mixtures of Distributions, and the EM Algorithm”, Massachusetts Institute of Technology, *Neural Computation* 6, 334-340, 1994.
- Zaki M.J., Meria Jr. W. “ Data Mining and Analysis, Fundemantal Concepts and Algorithms” (Ed: Lauren Cowles), Cambridge University Press, New York, NY, A.B.D., pp 13, 2014.
- Zhang Z. , Chen C., Sun J. ve Chan K. L., “EM algorithms for Gaussian mixtures with split-and-merge operation”, *PERGAMON, Pattern Recognition*, 36 , 1973–1983, 2003.
- Zhong M., Tang H., Wang H. ve Tang Y., ” An EM Algorithm for Independent Component Analysis in the Presence of Gaussian Noise”, *Neural Information Processing-Letters and Reviews*, Vol. 2, No. 1, 11-17, 2004.