

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

JEODEZİ VE FOTOGRAMETRİ MÜHENDİSLİĞİ ANABİLİM DALI

**UZAKTAN ALGILAMADA GÖRÜNTÜ SINIFLANDIRMA YÖNTEMLERİ
ANALİZİ**

YÜKSEK LİSANS TEZİ

Harita Müh. Oğuz KANSU

**AĞUSTOS 2006
TRABZON**

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

JEODEZİ VE FOTOGRAMETRİ MÜHENDİSLİĞİ ANA BİLİM DALI

**UZAKTAN ALGILAMADA GÖRÜNTÜ SINIFLANDIRMA YÖNTEMLERİ
ANALİZİ**

Harita Müh. Oğuz KANSU

**Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde
“Harita Yüksek Mühendisi”
Unvanı Verilmesi İçin Kabul Edilen Tezdir.**

Tezin Enstitüye Verildiği Tarih : 29.06.2006

Tezin Savunma Tarihi : 07.08.2006

Tez Danışmanı : Y. Doç. Dr. Eminnur AYHAN

Jüri Üyesi : Doç. Dr. Çetin CÖMERT

Jüri Üyesi : Prof. Dr. Selahattin KÖSE

Enstitü Müdürü : Prof. Dr. Emin Zeki BAŞKENT

Trabzon 2006

ÖNSÖZ

“Uzaktan Algılamada Görüntü Sınıflandırma Yöntemleri Analizi” adlı bu çalışma, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Jeodezi ve Fotogrametri Mühendisliği Anabilim Dalında Yüksek Lisans Tezi olarak hazırlanmıştır.

Çalışma süresince bilgi, görüş ve yardımlarını esirgemeyen değerli hocam Sayın Yrd. Doç. Dr. Eminnur AYHAN’ a şükranlarımı sunarım.

Tezi hazırlamam esnasında karşılaştığım problemlere gösterdiği ilgi ve yardımlarından dolayı sayın hocam Doç. Dr. Taşkın KAVZAOĞLU’ a teşekkür ederim.

Çalışmalarım sırasında manevi desteğini hiçbir zaman eksik etmeyen, her zaman yanımda olan sevgili Esra ÇEVİKBAŞ’ a,

Yardımları ve desteği ile sevgili arkadaşım Araştırma Görevlisi Burak SATIR’ a,

Lisans ve yüksek lisans öğrenimimde hiç bir zaman manevi desteklerini eksik etmeyen Jeodezi ve Fotogrametri Mühendisliği Bölümü öğretim elemanlarına ve daha önceki eğitim öğretim hayatımda emeği geçen tüm hocalarıma teşekkürlerimi sunarım.

Son olarak, hayatımın her anında olduğu gibi, tez çalışmalarım sırasında da maddi manevi büyük desteklerini gördüğüm değerli annem, babam ve ağabeyime sonsuz sevgilerimi sunarım.

Oğuz KANSU

Trabzon 2006

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ	II
İÇİNDEKİLER	III
ÖZET.....	VI
SUMMARY	VII
ŞEKİLLER DİZİNİ	VIII
TABLolar DİZİNİ	XI
SEMBOLLER DİZİNİ	XIII
1. GENEL BİLGİLER	1
1.1. Giriş	1
1.2. Uzaktan Algılama	3
1.2.1. Elektromanyetik Enerji	4
1.2.2. Elektromanyetik Spektrum	5
1.2.3. Atmosfer Etkisi.....	6
1.2.4. Standart Terimler ve Birimler.....	7
1.3. Uzaktan Algılamada Uydu Sistemleri	9
1.3.1. Ikonos Uydu Sistemi.....	9
1.4. Sınıflandırma	11
1.4.1. Sınıflandırma Yöntemleri	13
1.4.1.1. Kontrollü Sınıflandırma	13
1.4.1.1.1. En Kısa Uzaklık Karar Kuralı.....	15
1.4.1.1.2. Paralelkenar Karar Kuralı	16
1.4.1.1.3. Maksimum Olabilirlik Karar Kuralı	18
1.4.1.1.4. Mahalanobis Uzaklığı Karar Kuralı	21
1.4.1.2. Kontrolsüz Sınıflandırma	22
1.4.1.2.1. Ardışık Kümeleme Yöntemi	23
1.4.1.2.2. ISODATA Yöntemi (Tekrarlı Kendini Organize Eden Veri Analiz Tekniği)	24

1.4.1.2.3.	İstatistiksel Kümeleme Yöntemi	25
1.4.1.2.4.	RGB Kümelemesi	26
1.5.	Yapay Sinir Ağları	27
1.5.1.	Tanım ve Özellikler	27
1.5.1.1.	Biyolojik Sinir Ağı: Beyin	30
1.5.1.2.	İşlemci Eleman (Yapay Nöron)	31
1.5.1.3.	Aktivasyon Fonksiyonu	34
1.5.2.	Yapay Sinir Ağlarının Sınıflandırılması	35
1.5.2.1.	YSA' ların Yapılarına Göre Sınıflandırılması	36
1.5.2.1.1.	İleri Beslemeli Ağlar	36
1.5.2.1.2.	Geri Beslemeli Ağlar	37
1.5.2.2.	YSA' ların Öğrenme Algoritmalarına Göre Sınıflandırılması.	37
1.5.2.2.1.	Kontrollü Öğrenme	37
1.5.2.2.2.	KontROLSÜZ Öğrenme	37
1.5.2.2.3.	Takviyeli Öğrenme	38
1.5.3.	Çok Katmanlı Algılayıcı.	38
1.5.3.1.	Geri Yayılım Öğrenme Algoritması	39
1.5.4.	YSA ile Görüntü Sınıflandırma	46
1.5.4.1.	Ön İşleme	47
1.5.4.2.	Ağ Girişinin Kodlanması	47
1.5.4.3.	Ağ Çıkışının Kodlanması.....	48
1.5.4.4.	Sınıfların Çıkarılması	49
1.5.4.5.	Ağ Topolojisi	49
1.5.4.6.	YSA' da Eğitim	50
1.6.	Bulanık Mantık Kavramı	50
1.6.1.	Bulanık Model	51
1.6.2.	Bulanık Modelleme Çeşitleri	53
1.6.2.1.	Mamdani Tipi Bulanık Modelleme	54
1.6.2.2.	Takagi – Sugeno Tipi Bulanık Modelleme	55
1.6.3.	Matlab Bulanık Mantık Modülü.....	57
1.7.	Sınıflandırmada Doğruluk Analizi.....	59
2.	YAPILAN ÇALIŞMALAR.....	62
2.1.	Çalışma Alanı	62

2.2.	Kullanılan Donanım ve Yazılım Özellikleri	62
2.3.	Kullanılan Veri Modeli	63
2.4.	Bilgi Sınıfları ve Eğitim Alanlarının Belirlenmesi.....	63
2.5.	Kontrollü Sınıflandırma Uygulaması	69
2.6.	Yapay Sinir Ağları Uygulaması	70
2.6.1.	Patern Dosyalarının Hazırlanması ve Örneklenmesi	72
2.6.2.	Ağ Dosyasının Oluşturulması	77
2.6.3.	Konfigürasyon Dosyalarının Hazırlanması ve Koşturulması	78
2.6.4.	Yapay Sinir Ağlarının Test Edilmesi	79
2.6.5.	Doğruluk Analizi.....	80
2.6.6.	Görüntü Dosyalarının Hazırlanması	82
2.7.	Bulanık Mantığa Dayalı Görüntü Sınıflandırma Uygulaması	83
2.7.1.	Bulanık Çıkarım Sisteminin Oluşturulması	83
2.7.2.	Üyelik Fonksiyonunun Oluşturulması	84
2.7.3.	Kural Düzenleyicisinin Oluşturulması	88
2.7.4.	Kural Görüntüleyici	89
2.7.5.	Sınıflandırma Aşaması ve Doğruluk Analizi	90
3.	BULGULAR VE İRDELEME	93
3.1.	Yapay Sinir Ağı Tasarımında Ağ Parametrelerinin İrdelenmesi	93
3.1.1.	Girdi Katman Sayısının İrdelenmesi	94
3.1.2.	Ara Katman Sayısının İrdelenmesi	95
3.1.3.	Öğrenme Oranı ve Momentumun İrdelenmesi	96
3.1.4.	İlk Ağırlık Parametresinin İrdelenmesi	99
3.1.5.	Çıktı Kodlamasının İrdelenmesi	102
3.1.6.	Yapay Sinir Ağları İçin En İyi Tasarımın Belirlenmesi	104
3.2.	Landsat Uydu Görüntü Verisi Kullanılarak Yapılan Sınıflandırmaların İrdelenmesi.....	104
3.3.	Genel Karşılaştırma	105
4.	SONUÇLAR VE ÖNERİLER	112
5.	KAYNAKLAR	115
6.	EKLER	117
	ÖZGEÇMİŞ	120

ÖZET

Uzaktan algılamanın sonuç ürünü olarak istenen tematik haritaları yüksek doğrulukla etkin bir şekilde üreten sınıflandırma yöntemleri geliştirmek yoğun çalışmaların yapıldığı önemli bir araştırma konusudur. Literatürde yoğun olarak kullanılan klasik istatistiksel sınıflandırma yöntemlerine (Maksimum Olabilirlik, Mahalanobis uzaklığı vb.) ek olarak son yıllarda Yapay Zeka yaklaşımları sınıflandırma problemlerinin çözümünde kullanılmaya başlanmıştır. Temelde insan zekası davranışlarını makineye aktarmaya çalışan yapay zeka uygulamaları genel olarak; Bulanık (Fuzzy) Mantık, Uzman Sistemler, Genetik ve Tabu Arama ve Yapay Sinir Ağları (YSA) olarak alt başlıklara ayrılmaktadır. Bunlardan YSA ve Bulanık Mantık yöntemleri literatürde çok spektrumlu uydu görüntü verilerinin sınıflandırılması için üzerinde en çok araştırmanın yapıldığı alan olmuştur.

Bu çalışmada çok spektrumlu IKONOS II görüntü verisinin sınıflandırılması için klasik Maksimum Olabilirlik yöntemi, YSA sınıflandırma yöntemi ve Bulanık Mantığa Dayalı Sınıflandırma yöntemlerinin karşılaştırılması amaçlanmıştır. Ayrıca çalışmada kullanılan YSA algoritmalarından geri yayımlı öğrenme algoritması için ağ yapısı ve birincil parametre tahminlerinin seçimindeki etkiyi geniş kapsamlı olarak araştırmak amaçlanmıştır.

Anahtar Sözcükler: Uzaktan Algılama, Sınıflandırma, Yapay Sinir Ağları, Bulanık Mantık

SUMMARY

Analysis of Image Classification Methods for Remote Sensing

Many researches have been done many studies to develop new classification methods for production of thematic maps efficiently and accurately. Besides the common methods used intensely in literature (Maximum Likelihood, Mahalanobis distance etc.), the artificial intelligence approaches have been used to solve the problems based on the classification recently. The artificial intelligence which basically aims to mimic the intelligence of human beings onto the machines is generally divided into Fuzzy Logic, Expert Systems, Genetic and Tabu Search and Artificial Neural Networks (ANN). Among these, the ANN and Fuzzy Logic techniques are the most common and basic method which the most researches have been applied to classification problems in literature.

In this study for classification of multispectral IKONOS II imagery, it was aimed to compare ANN classification with the standart maximum likelihood method and image classification based on fuzzy logic method. Moreover it is achieved to research the effect of selection of network structure and primary parameter estimations for the backpropagating learning algorithm which is the one of the artificial neural network algorithm that is used in this study.

Key words: Remote Sensing, Classification, Artificial Neural Networks, Fuzzy Logic

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1.1.	Uzaktan algılama sistemi 4
Şekil 1.2.	Elektromanyetik enerjinin dalga karakteri 4
Şekil 1.3.	Elektromanyetik spektrum 5
Şekil 1.4.	Saçılma..... 6
Şekil 1.5.	İki boyutlu uzayda sınıflandırma 13
Şekil 1.6.	Kontrollü sınıflandırma 14
Şekil 1.7.	En kısa uzaklık karar yöntemi 15
Şekil 1.8.	İki boyutta paralel kenar sınıflandırıcı 17
Şekil 1.9.	Maksimum Olabilirlik Yöntemiyle Oluşturulmuş Yoğunluk Fonksiyonu 19
Şekil 1.10.	En Çok Benzerlik Yöntemi ile Sınıflandırma 20
Şekil 1.11.	Sinir Sisteminin Blok Diyagramı 30
Şekil 1.12.	Biyolojik Nöronun Genel Yapısı ve İşlevleri 33
Şekil 1.13.	Yapay Nöronun Genel Yapısı 33
Şekil 1.14.	Aktivasyon fonksiyonları; (i) sigmoid, (ii) tanjant hiperbolik, (iii) lineer, (iv) keskin sınırlayıcı, (v) gauss, (vi) çoklu-kuadratik 35
Şekil 1.15.	Çok katmanlı algılayıcı ağ yapısı 39
Şekil 1.16.	Geri-yayılm akış şeması 44
Şekil 1.17.	YSA' da örnek giriş kodlaması 48
Şekil 1.18.	Bulanıklaştırma – durulaştırma birimli bulanık sistem 52
Şekil 1.19.	Bulanık VE ve VEYA işlemleri için sırasıyla minimizasyon ve maksimizasyon operatörlerini kullanan Mamdani tipi bulanık çıkarım sistemi 55
Şekil 1.20.	Sugeno tipi bulanık model gösterimi..... 56
Şekil 1.21.	Bulanık Mantık Modülü Grafikselsel Kullanıcı Arayüzü 58
Şekil 2.1.	Çalışma Alanı (IKONOS II, RGB: 3/2/1 doğal renkli uydu görüntüsü) .. 62
Şekil 2.2.	Eğitim alanlarının seçilmesi 66
Şekil 2.3.	İki boyutlu özellik uzaylarında eğitim örneklerinin dağılımları 67
Şekil 2.4.	YSA ile sınıflandırmada hesap akış şeması 71

Şekil 2.5.	Eğitim ve test alanlarını içeren 5 bantlı uydu görüntüsü	72
Şekil 2.6.	MA_PAT program menüsü	73
Şekil 2.7.	Birinci örnekleme adımına ait metin dosyası	73
Şekil 2.8.	Dikdörtgen alanın seçimi	74
Şekil 2.9.	MA_PAT programında görüntü verisinin programa okutulması işlemi ...	75
Şekil 2.10.	İkinci örnekleme adımına ait metin dosyası	75
Şekil 2.11.	Rasgele örnekleme yapılarak patern sayılarının her sınıf için seçilmesi işlemi	76
Şekil 2.12.	BIGNET programı ara yüzü	77
Şekil 2.13.	Çalışmada kullanılan konfigürasyon dosyası	78
Şekil 2.14.	Konfigürasyon dosyalarının SNNS' in Batchman modülünde işletilmesi	79
Şekil 2.15.	Test sonuç dosyalarının hazırlanması için kullanılan konfigürasyon dosyası	80
Şekil 2.16.	Sınıflara ait bilgi dosyası	80
Şekil 2.17.	Olasılık matrisiyle yapılan doğruluk analizi	81
Şekil 2.18.	ID_IMG programı ara yüzü	82
Şekil 2.19.	Bulanık mantığa dayalı görüntü sınıflandırılmasında akış şeması.....	83
Şekil 2.20.	FIS düzenleyicisi paneli	84
Şekil 2.21.	Üyelik Fonksiyonu Düzenleyicisi Paneli	85
Şekil 2.22.	Üyelik fonksiyonu eklenti paneli	85
Şekil 2.23.	Kural editör paneli	89
Şekil 2.24.	Kural görüntüleme paneli	90
Şekil 3.1.	Ağın eğitiminde kullanılan girdi katman sayısı ve iterasyon sayılarının toplam doğruluktaki değişime etkileri.....	94
Şekil 3.2.	Görüntü verisi için ara katman sayısının sınıflandırma doğruluğu üzerindeki etkisi	95
Şekil 3.3.	Tablo 1.9' da verilen bulguların performans karşılaştırmaları	96
Şekil 3.4.	Farklı öğrenme oranları için üretilen toplam sınıflandırma doğrulukları analizi	97
Şekil 3.5.	Farklı öğrenme oranları ve momentumlar için üretilen toplam sınıflandırma doğrulukları analizi.....	98
Şekil 3.6.	İlk ağırlığı [0, 1]' e bağlı olarak üretilen sınıflandırma doğruluğundaki değişimler	99
Şekil 3.7.	İlk ağırlığı [-0.1, 0.1]' e bağlı olarak üretilen sınıflandırma doğruluğundaki değişimler	100
Şekil 3.8.	İlk ağırlığı [-0.15, 0.15]' e bağlı olarak üretilen sınıflandırma doğruluğundaki değişimler	100

Şekil 3.9.	İlk ağırlığı [-0.25, 0.25]' e bağılı olarak üretilen sınıflandırma doğruluğundaki deęişimle	101
Şekil 3.10.	İlk ağırlığı [-0.3, 0.3]' e bağılı olarak üretilen sınıflandırma doğruluğundaki deęişimler	101
Şekil 3.11.	İlk ağırlığı [-0.5, 0.5]' e bağılı olarak üretilen sınıflandırma doğruluğundaki deęişimler	102
Şekil 3.12.	Farklı kodlama metotlarının sınıflandırma doğruluğuna etkileri	103
Şekil 3.13.	İkonos görüntü verisi için Maksimum Olabilirlik yöntemi ile yapılan sınıflandırma sonuç görüntüsü.....	106
Şekil 3.14.	İkonos görüntü verisi için Bulanık Mantık yöntemi ile yapılan sınıflandırma sonuç görüntüsü.....	107
Şekil 3.15.	İkonos görüntü verisi için Yapay Sinir Ağları ile yapılan sınıflandırma sonuç görüntüsü.....	108
Şekil 3.16	Landsat görüntü verisi için Maksimum Olabilirlik yöntemi ile yapılan sınıflandırma sonuç görüntüsü.....	109
Şekil 3.17	Landsat görüntü verisi için Bulanık Mantık yöntemi ile yapılan sınıflandırma sonuç görüntüsü.....	110
Şekil 3.18	Landsat görüntü verisi için Yapay Sinir Ağları ile yapılan sınıflandırma sonuç görüntüsü.....	111

TABLULAR DİZİNİ

	<u>Sayfa No</u>
Tablo 1.1. Atmosferik pencere aralıkları.....	7
Tablo 1.2. Radyometrik terimler	8
Tablo 1.3. Oransal Radyometrik Birimler.....	9
Tablo 1.4. Ikonos uydusu platform özellikleri	10
Tablo 1.5. Ikonos uydusu yörünge özellikleri	11
Tablo 1.6. Ikonos uydusu sensör özellikleri	11
Tablo 1.7. Biyolojik sinir sistemi ve YSA sistemi arasındaki benzerlikler	32
Tablo 1.8. Aktivasyon fonksiyonlarının matematiksel yapıları	36
Tablo 1.9. En uygun ara katman sayısının hesaplanmasında araştırmacıların önerileri	50
Tablo 2.1. Sınıf Özellikleri	64
Tablo 2.2. Eğitim alanlarının poligon ve piksel sayıları.....	65
Tablo 2.3. Arazi sınıflarının bantlara göre ortalama yansıma değerleri ve standart sapmaları	65
Tablo 2.4. Bhattacharyya uzaklığı değerleri	68
Tablo 2.5. Dönüştürülmüş diverjans değerleri	68
Tablo 2.6. Uydu görüntüsünün Maksimum Olabilirlik sınıflandırma sonuçlarının hata matrisi	70
Tablo 2.7. Optimum ağ tasarımına göre sınıflandırma sonucu	82
Tablo 2.8. Eğitim alanlarının ortalama yansıma değerleri ve standart sapma değerleri	87
Tablo 2.9. Çıktı değişkenlerinin parametre değerleri	88
Tablo 2.10. Uydu görüntüsünün Bulanık Mantıkla yapılan sınıflandırma sonuçlarının hata matrisi	92
Tablo 3.1. Girdi katman sayılarının ürettikleri toplam doğruluk sonuçları.....	94
Tablo 3.2. Ara katman sayılarının ürettiği toplam doğruluk sonuçları	95
Tablo 3.3. Farklı öğrenme oranları için üretilen toplam sınıflandırma doğrulukları..	97
Tablo 3.4. Farklı öğrenme oranları ve momentumlar için üretilen toplam sınıflandırma doğrulukları.....	98

Tablo 3.5.	Çıktı kodlamalarının ürettikleri sınıflandırma sonuçları.....	103
Tablo 3.6.	Ikonos görüntü verisinde YSA tasarımı için en iyi ayarlar.....	104
Tablo 3.7.	Ikonos uydu görüntü verisi için bütün sınıflandırma yöntemleri için GD, Kappa ve üretici doğruluk değerleri.....	104
Tablo 3.8.	Landsat uydu görüntü verisi için bütün sınıflandırma yöntemleri için GD, Kappa ve üretici doğruluk değerleri.....	105

SEMBOLLER DİZİNİ

BR	İki Boyutlu Yansıtım (Bidirectional Reflectance)
DN	Dijital Numara (Digital Number)
EG	Esnek geri yayılma öğrenme algoritması
FOV	Görüş alanı (Field of View)
GD	Sınıflandırma genel doğruluk değeri
GIFOV	Yeryüzü anlık görüş alanı (Ground Instantaneous Field of View)
GSI	Yeryüzü örnekleme aralığı (Ground Sample Interval)
GU	Genel uygunluk değeri
IFOV	Anlık görüş alanı (Instantaneous Field of View)
ISODATA	Iterative Self Organizing Data kontrolsüz sınıflandırma algoritması
KaD	Kapa istatistiği doğruluğu
KD	Sınıflandırma kullanıcı doğruluk değeri
MLP	Çok katmanlı algılayıcı (Multi-Layer Perseptron)
MO	Maksimum olabilirlik sınıflandırma yöntemi.
MSS	Çok spektrumlu tarayıcı (Multi-Spectral scanner)
NIR	Kızılötesi bölge (Near Infrared)
OYF	Olasılık yoğunluk fonksiyonu
PSF	Noktasal Yayılım fonksiyonu (Point Spread Function)
RBF	Radyal Tabanlı Fonksiyon (Radial Basis Function)
SWIR	Kısa dalga kızılötesi bölge (Shortwave Infrared)
TIR	Termal (ısı) kızılötesi bölge (Thermal Infrared)
TM	Tematik haritalayıcı (Thematic Mapper)
ÜD	Sınıflandırma üretici doğruluk değeri
V	Görünür bölge (Visible)
YSA	Yapay sinir ağı

1. GENEL BİLGİLER

1.1. Giriş

Modern uydu algılama teknolojilerinin en önemli uygulamalarından biri, arazi örtüsü kullanımının uzaktan algılama ile haritalanması ve harita bilgilerinin üretilmesidir. Arazi kullanımının değişen biçimleri ekonomik, sosyal ve çevresel koşulların da değişimini yansıtır. Bu türden değişimlerin izlenmesi uluslar için her zaman önemli olmuştur.

Arazi kullanımının belirlenebilmesi görüntü sınıflandırılmasıyla mümkündür. Görüntü sınıflandırma, uzaktan algılama görüntülerinde aynı özelliğe sahip olan bölgelerin benzer şekilde gösterildiği tematik haritaların hazırlanması işlemidir. Orijinal algılanmış görüntü karar fonksiyonlarıyla ayrılmış özellik uzayı ile sonuç haritaya dönüştürülür. Bölgelerin ayırt edilmesinde kullanılan bilgileri, görüntü piksel değerlerini oluşturan spektral veriler, piksellerin komşuluk ilişkilerini açıklayan uzaysal doku veya kategorilerin uzaydaki konumsal bilgileri olabilir. Bu bilgiler ayrı ayrı kullanılacakları gibi bir arada da kullanılabilirler. Sınıflandırma işleminde başlıca iki yaklaşım vardır: (i) Kontrollü sınıflandırma ve (ii) Kontrolsüz sınıflandırma. Kontrollü sınıflandırmada, elde edilecek kategorileri temsil eden görüntü pikselleri toplanır ve ayırt edici karar fonksiyonları bu eğitim örneklerinden hesaplanır. Kontrolsüz sınıflandırmada ise kategorileri temsil eden örnekler bilinmeyip spektral olarak ayrılabilen kümeler oluşturulur. Kümelerin hangi kategorileri temsil ettikleri sınıflandırmadan sonra arazi incelemeleri ve harita ve hava fotoğraflarından yararlanılarak belirlenir. Sınıflandırma uygulamalarında kullanılan Maksimum Olabilirlik, Paralelkenar Yöntemi, En Kısa Uzaklık Yöntemi, Mahalanobis Uzaklığı Yöntemi gibi klasik istatistik yöntemlerin yanında son yıllarda yapay zeka uygulamalarından Yapay Sinir Ağları (YSA), Bulanık Küme Teorisi, Uzman sistemler, Genetik Arama gibi yaklaşımlarda kullanılmaya başlamıştır.

Yapay zekanın bir kolu olan Bulanık Mantık, mantık kurallarının esnek veya bulanık bir şekilde uygulanmasını sağlar. Klasik mantıkta doğru ve yanlış, var ve yok ya da 1 ve 0 gibi ani geçişleri yumuşatmaktadır. Bu iki değer arasında da değerler bulunduğu, insan hayatına ve kararlarına bakıldığında hemen hemen hiçbir şeyin kesinlikle doğru veya kesinlikle

yanlış olmadığı göz önüne alınırsa böyle bir yaklaşımın farklılığı daha açık ortaya çıkmaktadır. Bulanık mantık teorisinin insan düşünme tarzına yakın olması, uygulanışı sırasında bir matematik modele ihtiyaç duyulmaması, donanım olarak gerçekleştirilebilmesi bilinen üstünlükleri iken uygulamada, kullanılan kuralların oluşturulmasının uzmana bağlılığı, üyelik fonksiyonlarının deneme-yanılma yolu ile bulunmasından dolayı uzun zaman alabilmesi, kararlılık analizinin yapılışının zorluğu ise bilinen dezavantajlarıdır.

Bulanık mantığın kullanım alanları gün geçtikçe artmaktadır. Görüntü işleme alanındaki uygulama alanları, görüntü tanımlama ve makine görüntülemesidir.

Yapay zekanın diğer bir kolu olan Yapay Sinir Ağları, birbirleriyle bütünüyle veya kısmi olarak bağlantılı işlemci elemanların oluşturduğu paralel bir yapıdır. Bu yapı içerisinde bilgi nöronlar arası bağlantılarda sinaptik ağırlık değerleri olarak saklanır. 1940'larda McCulloch ve Pitts' in yapay nöronu tanımlamasıyla bilimsel çevrelerde ilgi uyandıran YSA uygulamaları 1960 - 1980 yılları arasında yavaşlamış ve 1980'lerin ortalarından itibaren istatistiksel mekaniğin tekrarlı ağların açıklanmasında kullanılması ve çok katmanlı ağların eğitilmesi için geri yayılma öğrenme algoritmasının Rumelhart ve McClelland tarafından geliştirilmesiyle patlama şeklinde artmıştır. YSA yapılarında öğrenme, bilginin temsil edildiği ağı serbest parametrelerinin (ağırlık ve bias) belirli bir kritere göre güncellenmesidir. Ağ parametreleri kontrollü öğrenme yönteminde ağı ürettiği çıkış değerleriyle giriş verisine karşılık gelen hedef değerleri karşılaştırılarak güncellenir. Eğer iki değer arasındaki fark istenen sınırdan büyükse parametreler bu farkı istenen seviyeye azaltacak şekilde iteratif yapıda güncellenir. Başlangıç ağırlık ve kullanılıyorsa bias değerleri tesadüfi olarak atanır. Kontrolsüz öğrenme yönteminde ise çıkış değerleri bulunmayıp ağ giriş değerlerine en yakın tepkime değerine sahip olan nöron aktifleşir. Eğitim sürecinde giriş veri paternlerinden istatistiksel düzenlilik çıkarılır.

YSA yapıları uzman sistemlerden farklı olarak karmaşık kural kümelerine ihtiyaç duymaksızın örnek veri kümelerine dayanarak neden ve sonuç arasında otomatik olarak fonksiyonel bir ilişki geliştirir. YSA algoritmaları, öncül istatistiksel kabul gerektirmemeleri, farklı kaynaklardan gelen farklı karakterdeki bilgileri aynı anda kolaylıkla kullanabilmeleri, gürültüyü tolere edebilmeleri ve en önemlisi öğrenebilme (genelleme) kabiliyetlerinden dolayı oldukça büyük bir ilgi odağı olmuştur. Karar sınırları veri dağılımı ne olursa olsun orijinal veri dağılımına uyacak şekilde ağı eğitilmesiyle dengelenir. Bu avantajlarına karşın, standart evrensel bir YSA topolojisinin

tanımlanamaması ve eğitim zamanının uzunluğu en büyük dezavantajlarıdır. Giriş ve çıkış verileri arasında kurulan ilişkinin anlaşılmasının genellikle mümkün olmaması YSA' ya bir kara kutu özelliği kazandırır. YSA katman sayılarının, bu katmanlardaki işlemci eleman (yapay nöron) sayılarının, veri giriş ve çıkış kodlamasının, gereken eğitim parametrelerinin (öğrenme ve momentum oranı, iterasyon sayısı veya hata değeri gibi) standart bir yapıya kavuşması için araştırmalar sürmektedir.

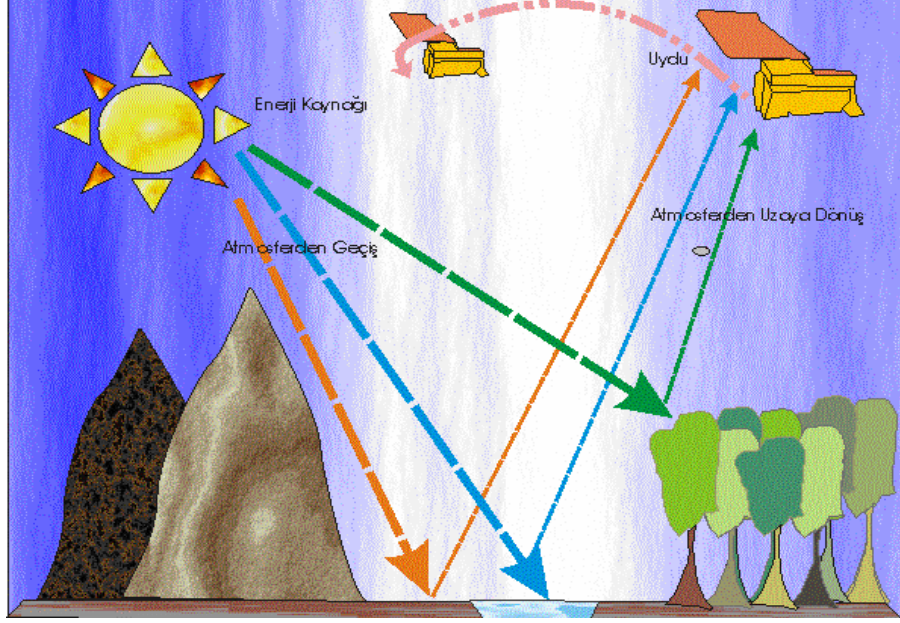
Bu tez çalışmasında çok spektrumlu uzaktan algılama görüntüsünün spektral tabanlı sınıflandırma işlemi Yapay Sinir Ağları, Bulanık Mantık ve Maksimum Olabilirlik yöntemleriyle yapılmıştır. Yapay Sinir Ağları ile görüntü sınıflandırma uygulaması için, geri yayımlı öğrenme algoritması kullanılmıştır. Bulanık Mantık ile yapılan uygulama için, Sugeno tipi bulanık model kullanılmıştır.

Bu çalışma kapsamında çok spektrumlu görüntü verisi olarak Ikonos II uydusundan alınan Trabzon ili Merkez ilçesi civarını içeren görüntü kullanılmıştır. Kullanılan YSA öğrenme algoritması için farklı ağ tasarımları belirlenerek sınıflandırma problemi için en uygun YSA tasarımının belirlenmesi amaçlanmıştır. Çalışmada kullanılan tüm ağ yapıları kendi aralarında karşılaştırıldığı gibi Bulanık Mantık ve Maksimum Olabilirlik yöntemleriyle de karşılaştırılarak en uygun yöntemin belirlenmesine çalışılmıştır.

1.2. Uzaktan Algılama

Uzaktan algılama bir cisimle direkt temas etmeksizin onun fiziksel özellikleri hakkında bilgi elde etme bilimi olarak tanımlanır. Jeoloji, ormancılık, hidroloji, tarım, şehircilik gibi bilim dalları uzaktan algılamanın uygulamalarının bulunduğu, bütünleştiği bilim dalıdır.

Uzaktan algılamayla kastedilen, uydular veya hava araçları üzerinde taşınan aletlerle yapılan gözlem ve ölçümler dikkate alınmaktadır. Uzaktan algılama sistemlerinde ölçülen nicelik, ilgilenilen cisimden yayılan elektromanyetik enerjidir. Uydular veya hava araçları üzerinde taşınan aletlerle yapılan gözlem ve ölçümlerde elektromanyetik enerjiden yararlanılır (Kavzoğlu, 2002).




Şekil 1.1. Uzaktan algılama sistemi

1.2.1. Elektromanyetik Enerji

Elektromanyetik enerji, harmonik dalgalar şeklinde, c ışık hızı ile hareket eden enerji şekillerinin bütünüdür. Işık, radyo dalgası, ısı, morötesi ve X ışınları elektromanyetik enerjinin çeşitli şekilleridir (Örmeci, 1987).

Elektromanyetik enerjinin şiddet, doğrultu, dalga uzunluğu, polarizasyon ve fazında değişme ancak katı, sıvı veya gaz halindeki bir cisimle temasında oluşur. Uzaktan Algılama, bu değişikliklerin saptanmasında rol oynar. Farklı doğrultulardaki elektromanyetik ışınımın algılayıcılar tarafından kaydedilmesi ile görüntülerin ve verilerin işlenerek yorumlanmasıyla spektral özellikler uzaktan belirlenmiş olur.



Şekil 1.2. Elektromanyetik enerjinin dalga karakteri


1.2.2. Elektromanyetik Spektrum

Elektromanyetik spektrum, 3.108 m/sn hızla hareket eden, dalga uzunluğu nanometrelerden kilometrelere kadar uzanan sürekli enerji ortamıdır.

Elektromanyetik spektruma dair diğer bir tanımlama ise, çeşitli dalga boylarındaki radyant enerjiyi içeren ve bu radyant enerjinin içinde elektromanyetik dalgalar halinde hareket ettiği bir ortam olarak ifade edilmektedir (Örmeci, 1987).

Elektromanyetik spektrum kolaylık olması bakımından çeşitli bölgelere ayrılmıştır. Buna göre;

- Mavi : (0.455-0.492 μ m)
- Yeşil : (0.492-0.588 μ m)
- Kırmızı : (0.720-1.300 μ m)
- Yakın Kızılötesi : (0.72-1.3 μ m)
- Orta Kızılötesi : (1.3-3.0 μ m)
- Termal Kızılötesi : (3.0-14 μ m)



Şekil 1.3. Elektromanyetik spektrum

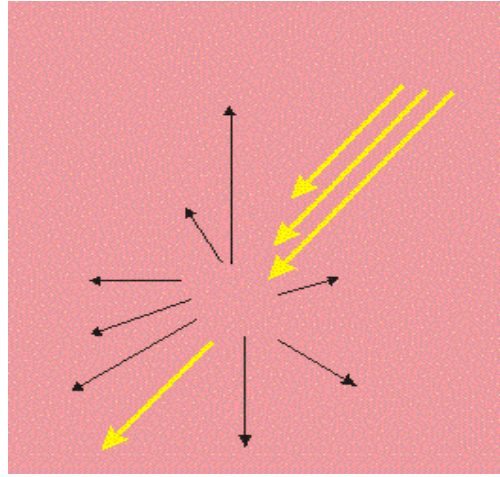
Yakın ve orta kızılötesinde ışınımın klorofil maddesine yani bitki örtüsüne duyarlıdır. Yakın kızılötesinde, açık kırmızı renk yüksek canlılık göstergesidir, renk soluksuzlaştıkça cansızlık söz konusu olur. 0.4-1.5 μ m elektromanyetik spektrum bölgesi bitki, toprak ve kimyasal araştırmalarda kullanılır.

Termal kızılötesi ise, görüntüsü alınan yeryüzü bölgesinin ısını gösterir. Bir bölgedeki kaya türleri, termal görüntülerdeki farklılıklara bağlı olarak gece ve gündüz incelenmesiyle deprem arařtırmalarında da yararlanır. Bu bölge dolaylı olarak mineral ve petrol arařtırmalarında da yarar saęlamaktadır (Sabins, 1987).

1.2.3. Atmosfer Etkisi

Atmosfer bir algılama sistemi tarafından algılanan ışının yoğunluk ve spektral bileşimine etki eder. Bu etkiler atmosferik yutulma ve saçılma sonucu ortaya çıkmaktadır (Örmeci, 1987).

Saçılma, ışının atmosferik taneciklerden yansması veya kırılması ile oluşur. Bu tanecikler, atmosferi oluşturan gaz molekülleri, toz tanecikleri ve geniş su damlacıklarıdır. Elektromanyetik enerjinin yüzeyde yön deęiřtirmesi Şekil 1.4' de gösterilmiştir (Çetin, 2001).



Şekil 1.4. Saçılma

Saçılma, saçılan ışının dalga boyu ile saçılma neden olan taneciklerin büyüklüğü arasındaki baęıntıya göre üç farklı kategoride incelenebilir:

1. Rayleigh Saçılımı: Işığın dalga boyunun saçan taneciklerden çok daha büyük olması halinde oluşur.
2. Mie Saçılımı: Işığın dalga boyunun atmosferdeki taneciklerle yaklaşık eşit büyüklükte olması durumudur. Bu saçılım genellikle çok puslu atmosfer

koşullarındaki optik spektrum boyunca oluşur ve görüntülerde kalite düşüklüğü olarak kendini gösterir.

3. Seçici Olmayan Saçılım: Taneciğin ışığın dalga boyundan çok daha büyük olması halinde oluşur (Kavzoğlu, 2002).

Yutulma ise, saçılımın tersine enerjinin yeryüzüne ulaşmadan atmosferde depolanması, bir açıdan kaybolmasıdır. Yutulma sırasında, ortama giren büyük frekanslı bir enerji daha küçük frekanslı bir enerjiye dönüştüğünden, atmosfer ısınmaktadır. Atmosferde ışınımı yutan kısımlar Yutulma Bantları olarak adlandırılır (Coşkun, 1992). Elektromanyetik enerjinin yutulmadan geçirildiği dalga uzunluğu bölgelerine ise Atmosfer Penceresi denir. Işığın bu bölgeler dışında atmosferden geçişinde veri elde edilememektedir (Özkan, 2001).

Tablo 1.1. Atmosferik Pencere Aralıkları

ATMOSFER PENCERESİ	SPEKTRAL BÖLGE (μm)
1	0.3-1.3
2	1.5-1.8
3	2.0-2.6
4	3.0-3.6
5	4.2-5.0
6	7.0-15.0

1.2.4. Standart Terimler ve Birimler

Uzaktan algılamadaki algılama sistemleri insan gözünden farklı oldukları için fotometrik birimler yerine radyometrik birimler kullanılır. Tablo 1.2' de radyometrik terimler birimleriyle birlikte verilmektedir.

Tablo 1.2. Radyometrik birimler

SEMBOL	TANIM	EŞİTLİK	BİRİM
Q	Işıyan Enerji		Jul
Φ	Işınır Akı(güç)	$\frac{dQ}{dt}$	Vat
M	Işınır çıkış	$\frac{d\Phi}{dA}$ (dışarı)	Metrekaredeki Vat
E	Birim ışınırılık	$\frac{d\Phi}{dA}$ (içeri)	Metrekaredeki Vat
L	Işınırılık	$\frac{d^2\Phi}{\cos\theta dAd\omega}$ (dışarı)	Metrekaredeki Steradyandaki Vat
$M\lambda$	Spektral ışınır çıkış	$\frac{dM}{d\lambda}$ (dışarı)	Metrekaredeki Mikrometredeki Vat
$E\lambda$	Spektral birim ışınırılık	$\frac{dE}{d\lambda}$ (içeri)	Metrekaredeki Mikrometredeki Vat
$L\lambda$	Spektral ışınırılık	$\frac{dL}{d\lambda}$	Metrekaredeki Steradyandaki Vat

Radyant (ışıyan, ışınır) enerji (Q) bütün doğrultularda ışınan toplam enerjidir. Işınır güç (akı) birim zamanda bütün doğrultularda ışıyan toplam enerjidir. Işınır çıkış (M) birim zamanda birim alan tarafından bütün doğrultularda ışıyan toplam enerjidir. Birim ışınırılık (E) birim zamanda birim alan üzerine düşen (ışıyan) toplam enerjidir. Işınırılık (L) birim katı açıda, birim zamanda, birim alandan ışıyan toplam enerjidir. Algılayıcı sistem tarafından ölçülen büyüklük olduğu için ışınırılık (L) uzaktan algılamada çok önemlidir. Tablodaki son üç terim yukarıda açıklanan radyometrik terimlerin belirli dalga boyları için olanlarıdır.

Bir materyali uzaktan algılamada tam olarak karakterize etmek için yukarıdaki terimler tek başlarına yeterli olmaz. Dünya yüzeyinin ışınır çıkışı (M), üzerine gelen birim ışınırılıkla (E) değişmektedir. Bu sebeple ışıyan enerjiyi veya ışınır çıkışı (M) açıklamak için birimsiz oransal terimler kullanılmaktadır. Bu terimler Tablo 1.3' de verilmektedir (Özkan, 2001).

Tablo 1.3. Oransal radyometrik terimler

NİCELİK	EŞİTLİK
Yayıml(ε)	M/Msiyahcisim
Yansıtım(ρ)	Φ _r / Φ _i
Yutulm(α)	Φ _a / Φ _i
Geçirim(τ)	Φ _t / Φ _i

Burada M ve Msiyahcisim sırasıyla ölçülen objenin ve aynı sıcaklığa sahip bir siyah cismin çıkışlarıdır. Φ_i ise, gelen akıdır.

Yayıml (ε), bir yüzeydeki ısıdır çıkışın aynı sıcaklıktaki ideal bir siyah cismin ısıdır çıkışına oranıdır. Yansıtım (ρ), yansıyan ısıdır akının gelen akıya oranıdır. Yutulma (α),yutulan ısıdır akının gelen ısıdır akıya oranıdır. Geçirim(τ), geçirilen ısıdır akının gelen akıya oranıdır.

1.3. Uzaktan Algılamada Uydu Sistemleri

Uzaktan algılama günümüzde birçok bilim dalı için önemli bir araç olmaktadır. Özellikle veri işleme sisteminin gelişmesi bu yöntemin kullanımını arttırmıştır.

Bilgisayarlar vasıtasıyla değerlendirilen verilerin elde edilişi, uydular kanalıyla gerçekleştirilmektedir. Birbirinden farklı disiplinlere yarar sağlayan uydu sistemleri arasından İkonos uydu sistemi aşağıda incelenmiştir.

1.3.1. İkonos Uydu Sistemi

İkonos görüntüleri, daha önce ticari olarak sağlanamayan ürün ve bilgileri, müşterilerin karar mekanizmalarında yardımcı olmak üzere sunmaktadır. Değişik uygulamalarda kullanılmak üzere yüksek detaylarda sunulan çok bantlı, renkli, siyah/beyaz (pankromatik), stereo ve 3 boyutlu İkonos ürünleri harita tabanlı bilgilerin üretilmesi, güncellenmesi ve bu bilgilerin birleştirilmesi için ideal bir ortam sağlar.

24 Eylül 1999'da Kaliforniya' daki Vandenberg Hava Üssünden fırlatılan İkonos uydusu ticari olarak en yüksek yersel sağladığı görüntüler 82cm çözünürlük ve 1 metre koordinat doğruluğu (RMSE) (1:2400 harita ölçeği) ile bugüne kadar ticari kullanıcılara

sağlanan en detaylı ve en hassas uydu görüntülerdir. Yüksek çözümü, geometrik doğruluğu, harita bazlı olması ve çok bantlı oluşu gibi özellikleri ile Uzaktan Algılama ve Coğrafi Bilgi Sistemleri çalışmalarında bir devrim anlamına gelen bu görüntüler yeryüzünün herhangi bir noktasından 1 ila 3 günde bir alınabilmektedir.

Ikonos uydusu 680 km irtifada 26,000 km/saat hızla ilerleyerek dünyayı 98 dakikada bir, güneş eş zamanlı bir yörüngede dönmekte ve dünyanın çevresini günde 14 defa dolaşmaktadır.

Ikonos uydusu iz düşümü boyunca 700 km eninde bir şerit içinde 82 cm çözünürlükte görüntü alabilmektedir. Alınan asgari görüntü 100 km alanında olup bir geçişte 10,000 km² ye kadar görüntü toplanabilmektedir. Uydu görüntülerinin yer kontrol noktalarıyla birlikte kullanımı, kesin yer tayini ve haritalama çalışmaları için kusursuz bir alan oluşturur. Ikonos uydusunun yüksek çözünürlüklü görüntüleri ile üretilmiş haritalar, değişik arazi özelliklerini gösterir. Bu haritalar geleneksel vektör haritalardan çok daha fazla detay sunar. Ikonos uydusuna ait platform, yörünge ve sensör özellikleri Tablo 1.4, Tablo 1.5 ve Tablo 1.6' da verilmiştir (URL- 1, 2006).

Tablo 1.4. Ikonos uydusu platform özellikleri

Fırlatma Tarihi	24 Eylül 1999 (11:21:08 am PDT)
Fırlatma Aracı	Athena II
Üretici Firma	Lockheed Martin
Fırlatma Merkezi	Vandenberg Air Force Base, California
Görüş Açısı	Her yönde yüksek manevra kabiliyeti
Ağırlık	725 kg

Tablo 1.5. Ikonos uydusu yörünge özellikleri

Yerden Yükseklik	423 mil/ 681kilometre
Eğilim	98.1 derece
Hız	Saniyede 4 mil / 7 kilometre
Alçalma zamanı	10:30 sabah
Yörünge Zamanı	98 dakika
Yörünge Tipi	Polara yakın; güneşle senkron

Tablo 1.6. Ikonos uydusu sensör özellikleri

Sensörler	Pankromatik, Çok Spektrumlu
Yersel Çözünürlük	Her filmin çözünürlüğü (izdüşümünden<26 derece uzaklıkta nominal) 1 metre pankromatik (tüm renklere duyarlı) ve (izdüşümünden<26 derece uzaklıkta nominal) 4 metre renklidir (birden fazla tayflı). Yeryüzü işleme programı tutarlı piksel yeryüzü örnek mesafesi (GSD) ile birlikte sorunsuz görüntü ürünleri ortaya çıkarmak için görüntüleri hızlı bir şekilde işlemektedir.
Görüntüye İlişkin Spektral Çözünürlük	Siyah-Beyaz: 0.45 - 0.90 mikron Renkli: (Landsat 4&5 TM Şeritleri #1-4 ile aynı) #1: Mavi 0.45 - 0.52 mikron #2: Yeşil 0.52 - 0.60 mikron #3: Kırmızı 0.63 - 0.69 mikron #4: Kızılötesine (IR) Yakın 0.76 - 0.90 mikron
Nominal Görüntü Şerit Genişliği	Nominal dolaşma genişliği:11 km
Yeniden aynı konuma gelme sıklığı	1 metre çözünürlükte 2.9 gün; 1.5 metre çözünürlükte 1.5 gün. Bu değerler 40 derece enlemindeki hedef yerler için geçerlidir. Uydunun yeniden aynı konuma gelmesi için geçen süre yüksek enlemlerde daha sık olurken ekvatora yakın enlemler de daha seyrek olacaktır.
Görüş açısı	Hareketli uzay aracı - doğrudan izleme ve yan izleme
Dinamik kapsamı	11 - bit data veya 8 - bit data

1.4. Sınıflandırma

Uzaktan algılamada sınıflandırma, bir görüntüdeki her bir piksel değerinin ait olduğu özellik grubunu belirleme işlemidir. Eldeki verilerden, o verilerin geldiği nesnelere ya da sınıfların bulunmasıdır. Sınıflandırma, genel olarak nesnelere farklı spektral yansıtımlarına dayandırılır. Sınıflandırma da amaç, aynı spektral özellik taşıyan nesnelere

gruplamaktır. Sınıflandırmanın yapılabilmesi için çok spektrumlu veri kullanılır. Her bir piksele ait spektral özellik verisi sınıflandırma için nümerik değerleri oluşturur. Her nesne çeşidi doğasındaki spektral yansıtım ve yutulmaya bağlı olarak farklı DN (dijital numaralarla) ifade edilirler.


Sınıflandırma işlemi, genel olarak şu adımları içerir;

1. Sınıflandırma projesi dizayn edilir; kullanılacak sınıflar tasarlanır, bu sınıflar, kent, tarım veya orman alanları olabilir. Arazi çalışması yapılarak, çalışma bölgesine ait yer bilgileri ve yardımcı veriler toplanır.
2. Görüntüdeki yeryüzü özelliklerini ortaya koyabilecek örnekleme bölgeleri seçilir ya da bilgisayarda kümeleme yöntemiyle örnekleme bölgeleri yaratılır.
3. Uygun algoritmalar seçilerek sınıflandırma yapılır.
4. Son işleme; geometrik düzeltme tamamlanır, filtreleme yapılır ve sınıflandırma düzenlenir.
5. Doğruluk değerlendirilmesi yapılır. Sınıflandırma sonuçları arazi çalışmalarıyla karşılaştırılır (URL- 2, 2006).

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

Sınıflandırma, tematik bilgi çıkarmak için kullanılan çok önemli bir yöntemdir. Dijital tematik harita haline getirilmiş sınıflandırılmış görüntü, bir harita projeksiyonuna dönüştürüldüğü durumda, coğrafi bilgi sistemlerinde kullanılabilir (Jehnsen, 1996).

Sınıflandırma yöntemleri, kontrollü ve kontrolsüz olmak üzere ikiye ayrılır. Bu iki sınıflandırma arasındaki farkın ortaya konulabilmesi için iki tür kavramdan söz etmek gerekir. Bu kavramlar; bilgi sınıfı ve spektral sınıftır. Bilgi sınıfı; kontrollü sınıflandırma da kullanılır ve belli bir kategoriye temsil etmek üzere analist tarafından seçilir. Öte yandan, spektral sınıf, benzer parlaklık değeri vektörlerinden oluşur ve bilgisayar tarafından belirlenir. Bilgi elde etmek için en ideal yöntem, bilgi sınıflarının ve spektral sınıfların birlikte kullanılmasıdır (URL- 2, 2006).



Şekil 1.5. İki boyutlu uzayda sınıflandırma

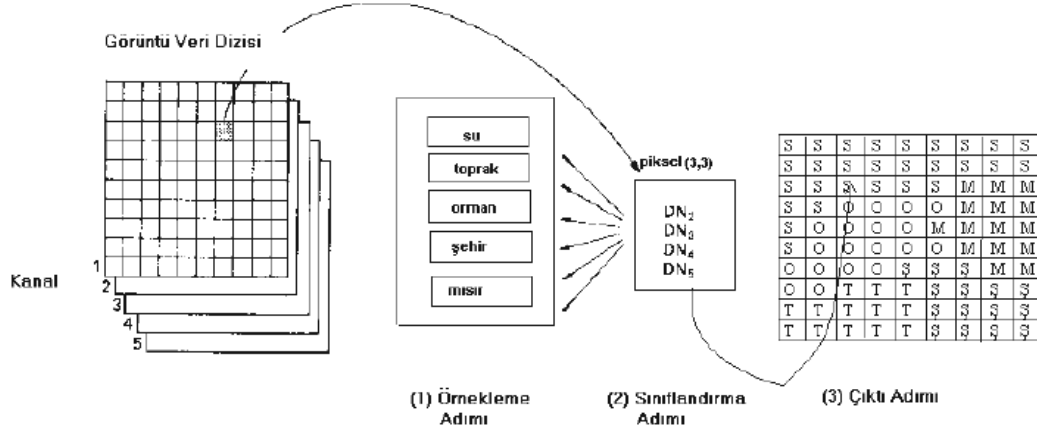
1.4.1. Sınıflandırma Yöntemleri

1.4.1.1. Kontrollü Sınıflandırma

Kontrollü sınıflandırma da, çalışma alanındaki yeryüzü özelliklerini tanımlayan yeteri sayıdaki örnekleme alanları kullanılarak, piksel değerlerinin özellik dosyaları oluşturulur. Kontrol alanlarının örneklediği özellik dosyalarının görüntü verilerine uygulanması ile her bir görüntü elemanı (piksel), hesaplanan olasılık değerine göre en çok benzer olduğu sınıfa atanmaktadır.

Kontrollü sınıflandırma üç adımda incelenilebilir.

1. Örnekleme Adımı ,
2. Sınıflandırma Adımı ,
3. Çıktı Adımı (Lillesand ve Kiefer, 2000).



Şekil 1.6. Kontrollü sınıflandırma

Kontrollü sınıflandırma da, ilk adım örnekleme adıdır. Örnekleme aşamasında, analist her bir arazi örtüsü çeşidini temsil edecek örnekleme bölgeleri seçer ve bu bölgelerin spektral özelliklerini açıklayacak sayısal değerler geliştirir.


İkinci adım, sınıflandırma adıdır. Sınıflandırma adımı, görüntü verisindeki her bir piksel en çok benzer olduğu arazi örtüsü kategorisine dahil edilir. Görüntü elemanı örnekleme bölgeleriyle uyum sağlamıyorsa 'bilinmeyen' olarak etiketlenir. Bilinmeyen piksel değerinin hangi arazi örtüsü grubuna dahil olacağı daha sonra belirlenir. Her bir piksele atanan sınıf, yorumlanmış veri dizisinde yerini alır ve böylece çok boyutlu görüntü matrisi, karşılık gelen yorumlanmış arazi örtü sınıfı tiplerinin oluşturduğu matrisi geliştirme de kullanılır.

Bütün veriler kategorize edildikten sonra sonuçlar çıktı adımı sunulur. Sonuçlar tematik haritalar, istatistiksel tablolar veya coğrafi bilgi sistemlerine dahil edilebilecek nitelikteki dijital veri kütükleri şeklinde ortaya koyulurlar (Lillesand ve Kiefer, 2000).

Kontrollü sınıflandırmada her bir örtü çeşidi için örnekleme bölgesi seçilmelidir, belirlenmediği takdirde sınıflandırılmayan veriler olacaktır. İyi bir sınıflandırma için örnekleme bölgeleri başarıyla belirlenmelidir. Örnekleme bölgelerini belirleme analistin sorumluluğunda olduğu için, analist ve görüntü verisi arasında iyi bir etkileşime gereksinim duyulur. Ayrıca analist verinin ait olduğu coğrafi alan hakkında iyi bilgiye sahip olmalıdır.

1.4.1.1.1. En Kısa Uzaklık Karar Kuralı

En kısa uzaklık karar kuralında, ilk olarak her bir örnek sınıfın ortalama vektörü bulunur. Bilinmeyen piksel ile her bir örnek sınıf için ortalama vektör arasındaki uzaklık hesaplanır. Bu uzaklıklara göre, bilinmeyen piksel en kısa mesafedeki örnek sınıfa atanır (Göksel, 1996).



Şekil 1.7. En kısa uzaklık karar yöntemi

Örnek sınıf ortalama vektörü ile bilinmeyen piksel arasındaki uzaklığa spektral uzaklık denir ve uzaklığın bulunması öklid uzaklığı esasına dayanmaktadır.

Spektral uzaklık;

n : kanalların sayısını

i : belli bir kanalı

c : belli bir sınıfı

X_{xyi} : i kanalındaki x, y pikselinin veri dizisini

M_{ci} : i kanalındaki c sınıfı için örneğin veri dizi değerlerinin ortalaması

SD_{xyc} : x, y pikselinden c sınıfı ortalamasına spektral uzaklık

$$SD_{xy} = \left(\sum_{i=1}^n (M_{ci} - X_{xyi})^2 \right)^{1/2} \quad (1)$$

formülünden bulunur.

Tüm olası sınıflar için spektral uzaklık hesaplandığında aday pikselin sınıfı, en küçük uzaklıkta olduğu sınıf olacaktır (Erdas Field Guide, 2002).


Matematiksel olarak basit ve hesaplama zamanı kısadır. Fakat spektral veride mevcut olan farklı derecedeki varyans değişimlerine duyarlı değildir. Bu durumdan kaynaklı olarak, bu metot ölçme uzayında spektral sınıfların birbirine çok yakın ve yüksek varyansa sahip olması durumunda kullanılmaz. Paralelkenar yönteminde bilinmeyen olarak kalan piksellerin bu yöntemle sınıflandırılması uygundur

Her bir piksel bir örnekleme grubunun ortaklama vektörüne yakın olacağı için sınıflandırılmamış piksel olmayacaktır. Diğer taraftan, bazen sınıflandırılmaması gereken pikseller de sınıflandırılmış olacaktır (Lillesand ve Kiefer, 2000).

1.4.1.1.2. Paralelkenar Karar Kuralı

Paralelkenar karar kuralında her bir örnek sınıfın her bir banttaki en düşük ve en yüksek DN değerleri dikkate alınarak, dikdörtgen alanlar oluşturulur. 'Bilinmeyen piksel', bulunduğu dikdörtgen bölgenin ait olduğu örnek sınıfa atanır (Lillesand ve Kiefer, 2000).

Parametrik olmayan bir yaklaşımdır. Hızlı ve basit bir yöntemdir. Bu yöntemin sonucunda sınıflandırılmayan piksel sayısı çoktur. Sınıflar arsında örtü alanı olması durumunda sınıflandırma zorlaşır. Bu durumda pikseller birbirini örten sınıflardan birine rasgele atanır.



Şekil 1.8. İki boyutta paralel kenar sınıflandırıcı

Paralelkenar kuralına diğer bir yaklaşım ise, ortalama değer ve standart sapma kullanılmasıyla ortaya çıkar. Bu yaklaşıma göre;

$c=1,2,3,\dots,m$ sınıf sayısını,

$k=1,2,3,\dots,n$ bant sayısını

μ_{ck} = k bandındaki c sınıfının ortalama değerini göstermek üzere,

Ortalama vektör kümesi;

$\mu_c=(\mu_{c1}, \mu_{c2}, \mu_{c3}, \dots, \mu_{cn})$ ile temsil edilir.

S_{ck} = k bandındaki c sınıfının standart sapmasını gösterir.

Her bir sınıfın ortalama değeri ve standart sapması hesaplanır. Bu değerler kullanılarak sınıflara ait sınır değerleri elde edilir. Alt ve üst sınır değerlerinden paralelkenarlar çizilerek her bir sınıfın sınırları belirlenir.

Bilinmeyen pikselin parlaklık değeri, BV_{ijk} ile gösterilir ve bu pikselin c sınıfına ait olması ancak;

$$\mu_{ck} - S_{ck} \leq BV_{ijk} \leq \mu_{ck} + S_{ck} \quad (2)$$

eşitliğini sağladığında mümkündür.

Bundan dolayı, alt sınır L_{ck} ile gösterilir ve $L_{ck} = \mu_{ck} - S_{ck}$ ve üst sınır H_{ck} ile gösterilir ve $H_{ck} = \mu_{ck} + S_{ck}$ eşitlikleri geçerlidir.

Bu durumda,

$L_{ck} \leq BV_{ijk} \leq H_{ck}$ olması durumunda bilinmeyen piksel BV_{ijk} c sınıfına atanır. Paralelkenar sınırları her bir sınıfın L_{ck} ve H_{ck} değerleri ile belirlenir. Bilinmeyen piksel, hangi sınıfın paralelkenar sınırı içine düşüyorsa o sınıfa atanır. Eğer bilinmeyen piksel, hiçbir sınıf aralığına düşmüyorsa, sınıflandırılmayan kategorisine atanır ve daha sonra farklı algoritmalarla sınıflandırılabilir (Jehnsen, 1996).


Sınıflar arasındaki örtü oranı, korelasyona veya yüksek kovaryansa sahip sınıfların dikdörtgen karar sınırları ile tam olarak tanımlanmaması nedeniyle oluşur. İki bantta benzer olarak değişen spektral değerlerin eğilimine kovaryans denir ve örnek uzayında sınıfların yana yatmasıyla sonuçlanır. Pozitif kovaryans, bir banttaki yüksek değerlerin, diğer banttaki yüksek değerlerle ya da bir banttaki düşük değerlerin diğer banttaki düşük değerlerle birleşmesi sonucu oluşur. Negatif kovaryans, bir banttaki yüksek değerlerin, diğer banttaki düşük değerlerle birleşmesi sonucunda meydana gelir. Kovaryans olmadığı durumda ise, örnek sınıf dairesel bir dağılım izlemektedir (Lillesand ve Kiefer, 2000).

Kovaryans olması durumunda bu yöntem zayıf sonuç verdiği için sınıfların sınırlarını belirleme de basamaklı yol izlenir.

1.4.1.1.3. Maksimum Olabilirlik Karar Kuralı

Maksimum Olabilirlik karar kuralında verilerin bant histogramlarının normal dağılımlı olduğu varsayılır. Maksimum Olabilirlik karar kuralı, bir pikselin belirli bir sınıfa ait olma olasılığına dayanır. Bu yöntemde sınıflandırılacak piksellerin varyans ve kovaryans değerleri hesaplanır (Ayhan vd., 2003).

Belirli bir patern ortalama vektör ve kovaryans matrisiyle tanımlanır. Bu parametrelerle, bir pikselin belli bir sınıfa ait olma olasılığı hesaplanır. Olasılık düzeyi ekseninde gösterilir, yataydaki iki ekseninde farklı bantlar yer alır. Bu değerlerle oluşan çan şeklindeki yüzey olasılık yoğunluk fonksiyonu olarak adlandırılır ve her bir spektral kategori için bir fonksiyon vardır.



Şekil 1.9. Maksimum Olabilirlik Yöntemiyle Oluşturulmuş Yoğunluk Fonksiyonu

Olasılık yoğunluk fonksiyonları, bilinmeyen piksellerin olasılıklarının hesaplanarak belirli bir sınıfa atanması için kullanılır. Aday piksel olasılık değerine göre en çok benzediği sınıfa atanır. Eğer aday pikselin olasılığı tüm sınıfların sınır değerlerinin altındaysa piksel 'bilinmeyen' olarak etiketlenir (Lillesand ve Kiefer, 2000).

Maksimum Olabilirlik yöntemiyle, X_i parlaklık değerinin k . inci sınıfa dahil edilebilme olasılığı hesaplanmakta ve X_i parlaklık değeri en yüksek olasılık değerine sahip olduğu sınıfa dahil edilmektedir.

$$P(X_i) = 2 \prod^{(-1/2)n|c|^{(-1/2)}} * e^{(-1/2)(X-\mu_k)(1/c)(X-\mu_k)} \quad (3)$$

ile ifade edilir.

$P(X_i)$: Bilinmeyen görüntü elemanının k . Sınıfa dahil olma olasılığı,

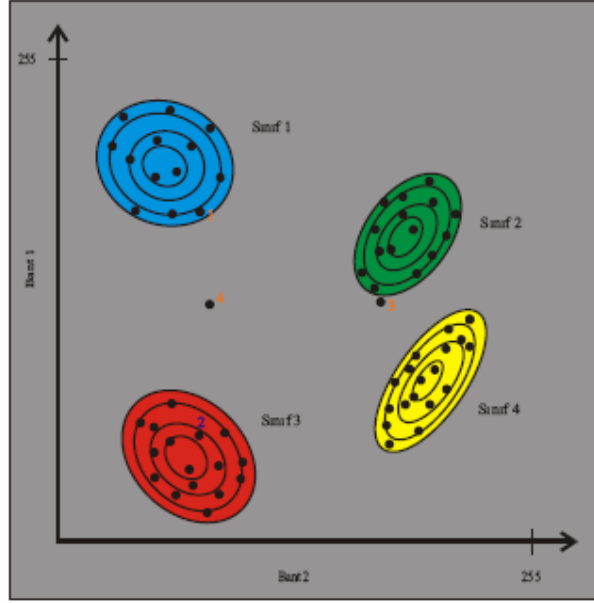
n : Kanal sayısı,

c : $n \times n$ boyuttaki k . sınıfına ait varyans-kovaryans matrisi,

X : n boyutundaki parlaklık değeri vektörü,

μ_k : k. sınıfına ait ortalama parlaklık değeri vektörünü göstermektedir.

Maksimum Olabilirlik yöntemi eşitliğinde; X_i parlaklık değerinin k. sınıfa dahil edilebilme olasılığı hesaplanmakta ve X_i parlaklık değeri en yüksek olasılık değerine sahip olduğu sınıfa dahil edilmektedir (Ayhan vd., 2003).



Şekil 1.10. Maksimum Olabilirlik Yöntemi ile Sınıflandırma

Maksimum Olabilirlik yöntemine diğer bir yaklaşım ise Bayesian algoritmasıdır. Bu yöntem de veri bantlarının normal dağılıma sahip olduğunu kabul eder. Yöntemin temel kuralı, bir görüntü elemanının belirli bir sınıfa ait olma olasılığına dayanmaktadır. Bayesian' a göre Maksimum Olabilirlik yönteminde bütün sınıflar için ağırlık faktörü 1 olarak kabul edilir. Eğer sınıflara ait farklı ağırlık değerleri önceden biliniyorsa eşitlikte bu değerlerde kullanılabilirler.

Yönteme ait eşitlik şu şekildedir;

D : ağırlıklı uzunluk,

C : belirli bir sınıf

x : ölçülen bilinmeyen görüntü elemanı (piksel),

μ_c : c sınıfının ortalama vektörü,

a_c : herhangi bir belirsiz pikselin c' ye ait olma olasılığı,

COV_c : c sınıfındaki piksellerin kovaryans matrisi,

$[COV_c]$: kovaryans matrisinin determinanı,

COV_c^{-1} : kovaryans matrisinin inversi,

\ln : doğal logaritma fonksiyonu,

T : fonksiyonun transpozese,

$$D = \ln(a_c) - [0,5 \cdot \ln([COV_c])] - [0,5 \cdot (X-\mu_c)^T \cdot (COV_c^{-1}) \cdot (X-\mu_c)] \quad (4)$$

Aday piksel ağırlıklı uzunluk değeri (D)' nin en düşük olduğu, c sınıfına atanır.

Yöntemin doğruluğu, seçilen örnekleme bölgelerinin doğruluğuna ve μ_k değerlerinin doğru hesaplanmasına bağlıdır (Erdas Field Guide, 2002).

Doğru örnekleme alanları sağlandığında en güçlü sınıflandırma metodudur. Bu yöntemin bir avantajıysa örtü alanlarındaki tahminleri istatistiksel olarak yapmasıdır.

Maksimum Olabilirlik yöntemi uygulaması, her bir piksel ve her bir bant için iki matris çarpımı işlemi içerdiği için uzun zaman alır. Bant sayısı arttıkça hesaplama süresi de artar. Parametrik bir yaklaşım olduğu için veri bantlarının normal dağılımlı olması önemlidir.

1.4.1.1.4. Mahalanobis Uzaklığı Karar Kuralı

Mahalanobis uzaklık algoritması, veri bantlarının normal dağılımlı olduğunu kabul eder ve bu durumda iyi sonuç verir. Yöntem en kısa uzaklık karar kuralına benzer fakat bu yöntemde kovaryans matrisi de kullanılır. Varyans ve kovaryans değişik özellikteki çeşitli sınıflar için denklemler karşılıklı olarak hesaplanır. Yüksek varyansa sahip kümeler aynı şekilde varyansa sahip sınıflara, düşük varyansa sahip kümeler düşük varyanslı sınıflara atanacaktır (Göksel, 1996).

Mahalanobis uzaklığı karar kuralında, minimum uzaklık ya da paralelkenardan farklı olarak sınıf değişimi göz önüne alınır. Mahalanobis uzaklığında işlenen örnekte ya da bir kümedeki piksellerde büyük bir dağılıma varsa o işaretin kovaryans matrisi büyük değerler içerecektir.

Mahalanobis uzaklığı;

$$D = (X-\mu_c)^T \cdot (COV_c)^{-1} \cdot (X-\mu_c) \quad (5)$$

eşitliğinden hesaplanır.

Eşitlikte;

D : Mahalanobis uzaklığı,

c : Belirli bir sınıf,

X : Sınıflandırılacak aday pikselin ölme vektörü,

μ_c : c sınıfı örneğinin ortalama vektörü,

COV_c : c sınıfı örneğindeki piksellerin kovaryans matrisi ,

COV_c^{-1} : COV_c matrisinin inversi,

T : Transpoze fonksiyonunu göstermektedir.

Sınıflandırılacak piksel, D Mahalanobis uzaklığının en düşük olduğu sınıfa atanır. Yöntem istatistik kriterlerin dikkate alınmasının zorunlu olduğu durumlarda en kısa uzaklık yönteminden daha yararlıdır. Diğer taraftan, paralelkenar ve en kısa uzaklık yöntemine göre daha yavaş hesaplama yapar. Yöntem parametrik olmasından dolayı veri bantlarının normal dağılımlı olması gerekmektedir. Örneklem bölgelerinin yüksek kovaryansa sahip olduğu bölgelere yönelme yapar (Erdas Field Guide, 2002).

1.4.1.2. Kontrolsüz Sınıflandırma

Kontrolsüz sınıflandırma, elde sınıfı bilinen yeterince piksel veya bunlarla ilgili olasılık dağılımları bilgisi bulunmadığı zaman ve açıkta çok fazla bilinmeyen piksel kaldığında kullanılır.

Kontrolsüz sınıflandırma üç adımda incelenebilir.

1. Sınıflandırma adımı,
2. Yorumlama adımı,
3. Sunum adımı.

Kontrolsüz sınıflandırmada, ilk olarak sınıflandırma adımında; her sınıftan gelen verilerin veri uzayında kümeler oluşturacağı varsayılarak, görüntüde doğal kümeler aranır. Burada temel olan, farklı sınıf tiplerine ait verilerin birbirinden ayrılması için belirli bir örtü tipine ait olan dijital değerlerin ölçme uzayında birbirine yakın konumda olmasıdır. Birbirinden iyi ayrılmış doğal kümeler bulunduğu durumlarda, eldeki ya da yeni bulunacak az sayıda örnekle sınıflandırma yapılabilir. Kontrolsüz sınıflandırma sonucu oluşacak sınıflar, spektral sınıflardır (Lillesand ve Kiefer, 2000).

Yorumlama adımında, oluşturulan sınıfların doğal özellikleri o bölgeye ait hava fotoğraflarıyla, topoğrafik haritalarla ve var olan diğer yer referans verileriyle karşılaştırılarak belirlenir.

Son adımda, kontrolsüz sınıflandırma sonucu elde edilen veriler tematik haritalar, istatistiksel tablolar halinde sunulur

Kontrollü sınıflandırma da önce kategorilere ait bilgiler tanımlanır ve sonra spektral özellik araştırılır; diğer taraftan, kontrolsüz sınıflandırmada, önce spektral özellikler tanımlanır ve daha sonra bilgiler atanır.

Kontrolsüz sınıflandırma tekniğinde görüntüdeki bütün spektral sınıflar tanımlanır. Bu yöntemde insan kaynaklı hatalar minimize edilir. Kontrollü sınıflandırma da analistin vermesi gerektiği kararlara, kontrolsüz sınıflandırma da gerek olmadığı için analist kaynaklı hatalar azalır.

1.4.1.2.1. Ardışık Kümeleme Yöntemi

Ardışık kümeleme yönteminde, pikseller aynı anda incelenir. Her bir analiz edilen piksel ile önceden oluşturulmuş kümelerin orta noktaları arasındaki mesafe hesaplanır. Her bir piksel, spektral uzaklıklarına göre var olan bir kümeye atanır ya da yeni bir küme oluşturur. Çok fazla küme oluşması durumunda kümeler birleştirilir.

Pikseller, görüntünün sol üst köşesinden başlayarak soldan sağa doğru satır satır analiz edilir. Bir pikselin ölçme vektörü bir kümenin ortalama vektörü olur ve ağırlığı 1'dir. Her bir kümenin ağırlığı, içindeki piksel sayısıdır. Kümelerin birleştirilmesi ve karşılaştırılmasında ağırlık dikkate alınır.

İki küme merkezi arasındaki minimum spektral uzaklık R 'dir ve bu değer analist tarafından belirlenir. Eğer analiz edilen piksel ve ona en yakın kümenin orta noktası arasındaki mesafe R ' den büyükse, analiz edilen piksel yeni bir küme oluşturur. Diğer taraftan, bu mesafe R ' den küçükse piksel en yakınındaki kümeye atanır.

Ardışık kümeleme yöntemi, çok az hazırlık ister ve bu yöntemde az parametre tanımlanmalıdır. ISODATA gibi iteratif metotlara göre daha hızlıdır. Fakat ardışık kümeleme yönteminde veri dosyasının üst kısmına yönelme olabilir. Bu yöntem parametrikdir, yani algoritma verilerinin normal dağılımlı olduğu kabul edilerek çalışır, komşu piksellerin homojenliği hesaba katılmaz. Arzu edilen sonucu elde etmek için

belirlenen girdi parametrelerini hesaplamak için deneme yanılma analizi gerekmektedir (Erdas Field Guide, 2002).

1.4.1.2.2. ISODATA Yöntemi (Tekrarlı Kendini Organize Eden Veri Analiz Tekniği)

ISODATA yönteminde de ardışık kümeleme yönteminde olduğu gibi spektral uzunluklar kullanılır. Fakat bu metotta;

- Keyfi belirlenmiş bir küme ortalama sayısı ile çalışma başlar.
- Tekrarlı olarak çalışır. Böylece bu keyfi ortalama değerler verideki kümenin ortalama değerine dönüşür.

ISODATA algoritmasında analist tarafından belirlenmesi gereken kriterler vardır. Bunlar;

C_{max} = algoritma tarafından tanımlanacak olan maksimum küme sayısı,

T = yaklaşma sınırı, bu sayıya ulaşıldığı zaman ISODATA algoritması biter, iterasyonlar arasındaki değişmezlik miktarıdır.

M = maksimum iterasyon sayısı,

P = bir kümede olması gereken minimum piksel sayısı.

ISODATA metodu iteratiftir çünkü belirlenen sonuçlara ulaşana kadar uzaktan algılama verisi üzerinde işlem yapar. İteratif olmasından dolayı veri dosyasının üst kısmına yönelme olmaz. ISODATA metodunun ilk iterasyonunda, N sayıdaki kümenin ortalamaları rasgele hesaplanır. Bu yeni ortalamalar, bir sonraki iterasyondaki kümeleri tanımlar. İşlem, iterasyonlar arasında çok az değişim olana kadar devam eder (Jehnsen, 1996).

Pikseller sol üst köşeden başlayarak, soldan sağa satır satır analiz edilir. Aday piksel ve her bir sınıfın ortalama vektörü arasındaki spektral mesafe hesaplanır. Piksel kendine en yakın olan kümeyle atanır.

ISODATA algoritması diğer kümeleme algoritmaları kadar parametrik olmadığı için normal dağılımlı olmayan verilerde iyi sonuçlar verir. Verideki spektral kümelerin bulunmasında başarılı bir algoritmadır.

ISODATA algoritması kümeleme işlemini pek çok kez tekrar ettiği için kümeleme metodları içinde en yavaş olanıdır. ISODATA yöntemi piksellerin homojenliğini hesaba katmaz (Erdas Field Guide, 2002).

1.4.1.2.3. İstatistiksel Kümeleme Yöntemi

İstatistiksel metot tek tek pikselleri eşit olarak dikkate almak yerine, komşu piksel gruplarının homojenliğini hesaba katar.

Algoritmada, benzer ölçme vektörlerine sahip 3x3' lük sürekli pikseller kullanılır. Diğer 3x3' lük pencereler dikkate alınmaz. Bu algoritmanın ardındaki düşünce, sürekli ve homojen piksellerin belli bir uzaysal paterni (örneğin bir arazi örtüsü çeşidi) bildirir ve bu da sınıflandırma anlamına gelir. Komşu piksellerin uzaysal ilişkisi dikkate alınır.

İstatistiksel metot iki aşamadan oluşur;

1. 3x3'lük matris penceresinde dikkate alınan piksellerin homojenliğinin kontrolü,
2. Kümelerin birleştirilmesi ve silinmesi.

9 pikselden oluşan 3x3'lük pencerelerin homojenliği test edilir, üst sol köşeden başlamak üzere pencere hareket ettirilir. Pencere üç piksel üzerinde de aynı zamanda hareket ettiği için, pencerelerde üst üste binme olmaz. Her bir bantta, 9 piksellik matris pencereleri için standart sapma ve ortalama hesaplanır. Standart sapma değeri ne kadar küçükse, penceredeki homojenlik o kadar yüksektir. Standart sapma değerinin yüksek olması, homojenliğin az olması demektir.. Minimum standart sapma değeri L ve maksimum standart sapma değeri U analist tarafından belirlenir. Minimum standart sapma değeri L oldukça küçük seçilir, fakat sıfıra eşit değildir. Daha sonra, hesaplanan standart sapma ve ortalama değerler analistin belirlediği değerlerle karşılaştırılır. Eğer pencere homojenlik testini geçerse küme oluşturur. Kullanıcının belirlediği küme sayısı değerini aşana kadar kümeler oluşturulmaya devam edilir (Erdas Field Guide, 2002).

Homojenlik Testinin Yapılması:

V : Varyans sabiti,

μ_i : i bandı için ortalama piksel değeri,

S_i : i bandındaki bir penceredeki piksellerin standart sapması,

M_i : i bandındaki bir penceredeki piksellerin ortalaması,

U : Standart sapma üst sınırı,

L : Standart sapma alt sınırı.

$G = \text{Max} (U_i, \mu_i * V/100)$

eşitliği kullanılarak,

Eğer, $S_i < L$ ise pencere küme tanımlama için kullanılmaz. (Uzaysal frekans yüksek).

Eğer, $S_i > G$ ise pencere küme tanımlama için kullanılmaz. (Uzaysal frekans çok düşük).

$L < S_i < G$ olması durumunda pencere i bandında homojendir. Eğer pencere her bantta homojense, küme oluşturma için kullanılır.

İstatistiksel kümelemede, sürekli piksellerin homojenliği test edilir. Bunu yaparken spektral ve uzaysal bilgiler dikkate alınır.

İstatistiksel testin sonuçları, homojenlik testi için analist tarafından girilen parametrelerle çok ilgilidir. Bu parametrelerin veri hakkında öncül bilgi olmadan hesaplanması zordur.

İstatistiksel olarak kümelenmiş verinin, en çok benzerlik yöntemiyle sınıflandırılması uygundur. Her iki metodun algoritması da aynı istatistiksel kriterleri kullanır (Erdas Field Guide, 2002).

1.4.1.2.4. RGB Kümelemesi

RGB kümelemesi basit bir sınıflandırmadır ve 3 bantlık 8 bit verinin sıkıştırılması için uygun bir tekniktir. Hızlı ve basit bir algoritmadır. Sınıflandırmanın hızlı yapılması gerektiğinde kullanılabilir; fakat her bir örtü çeşidini tanımlamaz.

Algoritma her bir pikseli 3 boyutlu spektral uzayda tarar ve bu uzayı $32 \times 32 \times 32$ 'lik gride böler. Bir kümenin sınıf olabilmesi için minimum sayıda piksele ihtiyaç vardır.

RGB kümelemesinde, 3 boyutlu ölçme uzayının her bir eksenini boyunca, her bir veri histogramı ölçeklenir. Böylece, her bir eksenindeki 32 pikselden oluşan bölmeler histogramları belli bir limite böler.

Bu algoritma da, 3 boyutlu ölçme uzayındaki her bir boyut 32 ve daha küçük olma şartıyla analistin belirleyeceği bölme sayısına ayrılır. Bölme sayısı her bir banttaki histograma göre değişir. Eğer histogram geniş bir aralıktaysa çok bölmeye, eğer histogram dar bir aralıktaysa az bölmeye ayrılır. Bir sınıfa atanması gereken minimum piksel sayısı ve atanacak sınıf sayısı analist tarafından belirlenir (Erdas Field Guide, 2002).

RGB kümeleme yöntemi, çok çeşitli sınıfların tanımlanmasına ihtiyaç duyulmadığı durumlarda kullanılabilir hızlı bir yöntemdir. Bu algoritma, veri dosyasının hiçbir yerine yönelme göstermez. Diğer taraftan, giriş verisi olarak mutlaka üç bant gereklidir ve bu yöntem her uygulama için uygun olmayabilir.

1.5. Yapay Sinir Ağları

1.5.1. Tanım ve Özellikler

Evrensel olarak kabul edilmiş bir YSA tanımı olmamasına rağmen bu alanda çalışan birçok araştırmacının kabul edeceği gibi; YSA her biri küçük bir yerel hafızaya sahip olan çok sayıda basit işlemci elemanların (yapay nöron) oluşturduğu bir ağdır. İşlemci elemanlar nümerik verinin iletiildiği iletişim kanallarıyla birbirlerine bağlanır. Her bir işlemci eleman (yapay nöron) sadece kendi yerel verisi ve bağlantılarıyla aldığı giriş sinyali üzerinde işlem yapar. YSA ile ilgili yapılan tanımlamalara örnek verilecek olursa;

- YSA, paralel yapıda çalışan çok sayıda basit işlemci elemandan oluşan, fonksiyonelliği ağıın yapısıyla, bağlantılarının etkinliğiyle ve işlemci elemanlardaki bağlantı işlemleriyle belirlenen bir sistemdir.
- YSA, deneysel bilgiyi depolayıp ve kullanıma uygun hale getirebilen bütünüyle paralel dağılımlı bir işlemci yapıdır. YSA beyinle iki şekilde benzeşmektedir:
 1. YSA bilgiyi eğitim işlemi ile elde eder.
 2. Sinaptik ağırlıklar olarak bilinen işlemci elemanlar (yapay nöron) arası bağlantı değerleri bilgiyi saklamak için kullanılır,

Yapay sinir ağı, nöral tabanlı çok sayıda basit işlemci elemandan oluşan bir devredir. Her bir eleman sadece kendine ait olan lokal bilgiyi işlemekte ve her bir eleman senkronize olmadan çalıştığı için sistemin genel bir zaman bilgisi olmamaktadır.

Yapay sinir ağları, katmanlar biçiminde düzenlenen basit işlem elemanı gruplarından oluşmaktadır. Her bir katman, farklı ağırlık değerlerine sahip olan bağlantılar aracılığıyla iletişimde bulunduğu belli sayıda işlem elemanını içermektedir. YSA' nın oluşturulmasında, hücrelerin karşılıklı bağlantı biçimleri ya da işlem elemanlarının düzenlenmesi, bilgiyi öğrenme ve bilgiyi kullanma yöntemi olarak üç temel elemana gereksinim vardır. YSA, ilgilenilen nesne hakkında hemen hemen hiçbir bilgi olmaması ya da çok az bilgi olması, bu nesnenin parametrelerinin ve durumunun matematiksel olarak ya da kuralla dayalı olarak tanımlanamaması ya da alışılmış işlemcilerle çözülemeyen problemlerin var olması durumlarında etkin olarak kullanılabilir bir yaklaşımdır. YSA' nın işlemsel özellikleri (Sağıroğlu vd., 1999):

1. *Lineer olmama*: Kullanılan aktivasyon fonksiyonuna bağlı olarak işlemci elemanlar lineer olmadığı için bu elemanların bağlantılarıyla oluşan ağda lineer değildir. Bu

özellik YSA' ya doğal olarak karmaşık ve lineer olmayan gerçek çevre problemlerine kabul edilebilir, etkin çözümler sağlama kabiliyeti verir.

2. *Öğrenme:* Klasik algoritmaların tersine YSA' lar kendi kurallarını eğitim kümesinden öğrenerek elde eder. Öğrenme, giriş veri kümesi ve istenirse bu girişlere karşılık gelen çıkış veri kümesinin, YSA' da verdiği tepkiye dayalı olarak ağın bağlantı ağırlıklarını bir öğrenme kuralına göre değiştirmesi veya uyarlamasıdır. Kontrollü öğrenmede YSA' nın sinaptik ağırlıklarının güncellenmesi işlemi, her bir giriş verisine karşı istenen çıkış verisinden oluşan öğrenme kümesinin uygulanmasıyla gerçekleştirilir. Sinaptik ağırlıklar (serbest parametreler), YSA' dan elde edilen çıkış değerleri ile olması gereken değerler arasındaki farkın tanımladığı uygun bir performans fonksiyonu optimize edilerek değiştirilir. Kontrolsüz sınıflandırmada ise giriş verilerine karşı çıkış verileri olmayıp YSA işlemci elemanları giriş verilerine göre kendilerini organize eder. Ağın eğitimi (sinaptik ağırlıkların değiştirilmesi) istenen istatistiksel kriter sağlanıncaya kadar sürdürülür. Giriş verileri, YSA' da ya tek tek vektörler halinde (sıralı öğrenme) veya giriş veri kümesi bütünüyle kullanılarak (grup öğrenme) işlenir.
3. *Genelleme:* YSA, ilgilendiği problemi öğrendikten sonra eğitim sırasında karşılaşmadığı test örnekleri için de belirtilen tepkiyi üretme kabiliyetine sahiptir. Örneğin, karakter tanıma amacıyla eğitilmiş bir YSA, bozuk karakter girişlerinde de doğru karakteri verebilir. Nöral hesaplamada hafızalar birleşiktir. Yani eğitilmiş ağa girişin sadece bir kısmı verilse bile, ağ hafızadan bu girişe en yakını seçerek tam bir giriş verisi alıyormuş gibi kabul eder ve buna uygun bir çıkış değeri üretir. Veri YSA' ya, eksik, bozuk veya daha önce hiç karşılaşmadığı şekilde verilse bile, ağ kabul edilebilir en uygun çıkışı üretecektir. Bu özellik ağın genelleme özelliğidir.
4. *Uyarlanabilirlik:* YSA, sinaptik ağırlıklarını çevre şartlarındaki değişmelere uyarlayabilme kabiliyetine sahiptir. Özellikle belirli bir çevre ortamında eğitilen YSA, çalışılan çevresel şartlardaki küçük değişmelere uyacak şekilde kolaylıkla tekrar eğitebilir. Ayrıca istatistiksel özellikleri zamanla değişen bir çevrede çalışılırken YSA sinaptik ağırlıkları gerçek zamanla değişecek şekilde dizayn edilebilir.

5. *Dağıtılmış birleşik hafıza*: YSA' ların en önemli özelliklerinden biri de bilgiyi depolamalarıdır. Nöral hesaplamalarda bilgi ağırlıklar üzerine dağıtılmıştır. Bağlantıların ağırlıkları nöral ağın hafıza birimidir. Bu ağırlıklar ağın o anda sahip olduğu bilgiyi veya uygulanan örneklerden öğrenmiş olduğu davranışı içerir. Bu bilgiler, ağıdaki birçok ağırlıklar üzerine (hafıza birimine) dağıtılır.
6. *Bağlamsal bilgi*: Bilgi, bir nöral ağın yapısal ve aktivasyonel durumuyla temsil edilir. Ağda bulunan her bir işlemci eleman, potansiyel olarak diğer bütün nöronların global aktivitesinden etkilenir. Bu ise bağlamsal bilgiyi YSA' nın doğal ilgi alanı yapmaktadır.
7. *Hata tolere edebilme*: Donanım şeklinde oluşturulmuş bir YSA' nın potansiyel olarak karşıt çalışma koşulları altında performansının dereceli olarak azalması anlamında doğal bir yeteneği vardır. Örneğin bir nöron veya onun bağlantısı zarar görürse bilginin ağıdaki dağıtılmış karakterinden dolayı ağın performansı ani ve büyük bir çöküntü şeklinde kayba uğramadan dereceli olarak yavaşça azalacaktır.
8. *Patern tanıma*: Patern tanıma problemleri çok sayıda verinin aynı anda işlenmesini, kategorisel ve genelleştirilmiş çıkış verilerinin üretilmelerini gerektirir. Ayrıca gürültü ve eksik bilginde kabul edilebilir seviyede işlenebilmesini gerektirir. YSA' lar belirli bir probleme özel tek bir çözüm üretebilecekleri gibi patern tanıma problemlerine de istenen seviyede çözümler sunabilmektedir.


YSA çok farklı disiplinler tarafından başarıyla kullanılmaktadır:

- Bilgisayar uzmanları; sembolik olmayan bilginin işlenmesi ve genel olarak öğrenme sistemlerinin özelliklerini öğrenmede,
- İstatistikçiler; esnek ve lineer olmayan regresyon ve sınıflandırma modellerinin çözümünde,
- Farklı mühendis grupları; sinyal işleme ve otomatik kontrol gibi bir çok alanda YSA' nın kullanım kapasitesinin araştırılmasında,
- İdrak üzerine çalışan bilim adamları; yüksek seviye beyin fonksiyonlarının (düşünme ve idrak) modellerinin açıklanmasında,
- Nöro-psikologlar; orta seviye beyin fonksiyonlarını (hafıza, algılama) ortaya çıkarma ve işleyişlerini açıklamada,
- Fizikçiler; istatistiksel mekanikteki ve diğer birçok alandaki problemlerini modellemede,
- Biyologlar; nükleotid dizilerinin yorumlanmasında.

1.5.1.1. Biyolojik Sinir Ağı: Beyin

Önceden de belirtildiği gibi, yapay sinir ağları insan beyninden esinlenilmiş yapılardır. Bu yüzden, YSA'ların yapısını anlamak için insan beyninin yapısını ve çalışma şeklini anlamak önemlidir. Bununla birlikte, tahmin edilebileceği gibi insan beyni, karmaşık yapısı ile anlaşılması ve anlatılması zor bir konudur. Hatta beynin çalışma şekli hala tam olarak anlaşılammıştır. Çok farklı bir disiplinin konusu olan bu temanın burada açıklanması gereksiz kalmaktadır. Ancak, en azından konunun özünün anlaşılabilmesi açısından bazı yararlı bilgiler verilebileceği düşüncesi ile genel bir açıklama yapılmaktadır.

İnsan beyni, sinir sisteminin merkezini oluşturan temel elemandır. En basit şekilde, sürekli olarak iletilen bilgiyi alır, idrak eder (işler) ve uygun kararları vererek gerekli yerlere iletir. Çok basit görünmekle birlikte aslında oldukça karmaşık olan bu yapının basit bir gösterimi Şekil 1.11' de sunulmaktadır (Haykin, 1999).



Şekil 1.11. Sinir Sisteminin Blok Diyagramı

Şekilden takip edilebileceği gibi, dışarıdan veya başka bir organdan gelen sinyaller (uyarı) alıcılar yoluyla sinir ağına iletilir. Sinyaller burada işlemde geçirilerek çıktı sinyaller oluşturulur. Oluşturulan çıktı sinyaller ise ileticiler yoluyla dış ortama veya diğer organlara iletilirler. Şekil 1.11' de Sinir Ağı olarak gösterilen ortadaki bölüm, yani beyin, sinir sisteminin merkezi konumundadır. Beynin temel yapı taşları ise sinir hücreleri, diğer bir ifadeyle nöronlardır. Beyin, işlevini birbirleri arasında yoğun bağlantılar bulunan bu yapı taşları ile yerine getirir. Nöronların en belirgin özelliği, vücudun diğer bölümlerinin tersine yeniden üretilmeyen belirli bir hücre türü olmasıdır. Beynin diğer temel yapısal ve fonksiyonel birimleri olan bağlantılar (synapses) nöronlar arası etkileşimi sağlarlar. Dolayısıyla, beynin yapısında bu bağlantılar da önemli bir yer tutmaktadır. Zaten beynin oldukça etkin çalışan bir organ olmasının temel sebebi de bu

yoğun bağlantılı yapıdır. Bu yapı sayesinde beyin, bugünkü bilgisayar teknolojisinden kat kat daha etkin bir şekilde çalışabilmektedir.

Beynin bu yapısı etkinlik açısından olduğu kadar bir diğer önemli özellik açısından da önem taşımaktadır. Bu yoğun bağlantılı yapı beynin plastiklik (yenilenebilme) özelliğini de beraberinde getirmektedir. Plastiklik özelliği, gelişmekte olan sinir sisteminin kendisini kuşatan çevreye adapte olmasını sağlamaktadır. Gelişmiş bir beyinde, plastiklik iki mekanizma ile izah edilebilmektedir. Bunlar, nöronlar arasında yeni bağlantıların oluşturulması ve var olan bağlantıların modifiye edilmesidir. Ayrıca, bu özellik öğrenme kavramı açısından da çok büyük önem taşımaktadır.

Plastikliğin, nöronların işlem yapabilmeleri için gerekli bir özellik olduğu görülmektedir. Çünkü, öğrenme süreci bağlantı ağırlıklarının değiştirilmesi veya yeni bağlantıların oluşturulması (hatta bazı bağlantıların iptal edilmesi) sayesinde gerçekleşmektedir. Bu ilişki, yapay nöronlar kullanarak beyinden esinlenilmiş sinir ağları oluşturulabilmesini sağlamaktadır (Yurtoğlu, 2005).

Yapay Sinir Ağları, beyinden esinlenildiklerinden dolayı benzer yapıya sahiptirler. Fakat, beyinin yoğun bağlantılı ve komplike yapısının sadece beyine özel bir özellik olduğu belirtilmelidir. Başka hiçbir yerde veya dijital bilgisayarda bulunmayan bu yapıya yakınsamak günümüz teknolojisine bile çok uzaktır. Yapay sinir ağlarını oluşturmak için kullanılan yapay nöronlar, beyindekilere kıyasla oldukça ilkel sayılırlar. Dolayısıyla, yapay nöronlar beyinin yoğun bağlantılı ve karışık yapısından hala oldukça uzaktırlar ama genel yapı olarak tutarlıdırlar. Diğer bir ifadeyle, YSA' lar, komplike, çok yönlü ve güçlü bir organizma olan beyinin sadece en temel elemanlarını kopyalamaya çalışmaktadır.

1.5.1.2. İşlemci Eleman (Yapay Nöron)

Yapay sinir ağlarının genel yapı olarak beyinden esinlendiği daha önce belirtilmişti. Doğal olarak, YSA' ların temel elemanları da yapay nöronlardır. Bu nöronlar, aralarındaki bağlantılar oluşturularak ve tabakalar halinde gruplandırılarak yapay sinir ağları oluşturulmaktadır.

İnsanın beyinsel gücünün bu yapı taşları birkaç genel işleve sahiptirler. Bir biyolojik nöron, temel olarak, diğer kaynaklardan girdiler alır, belirli bir şekilde bunları birleştirir, sonuç üzerinde bir işlem (genelde doğrusal olmayan) uygular ve nihai sonucu üretir. Şekil

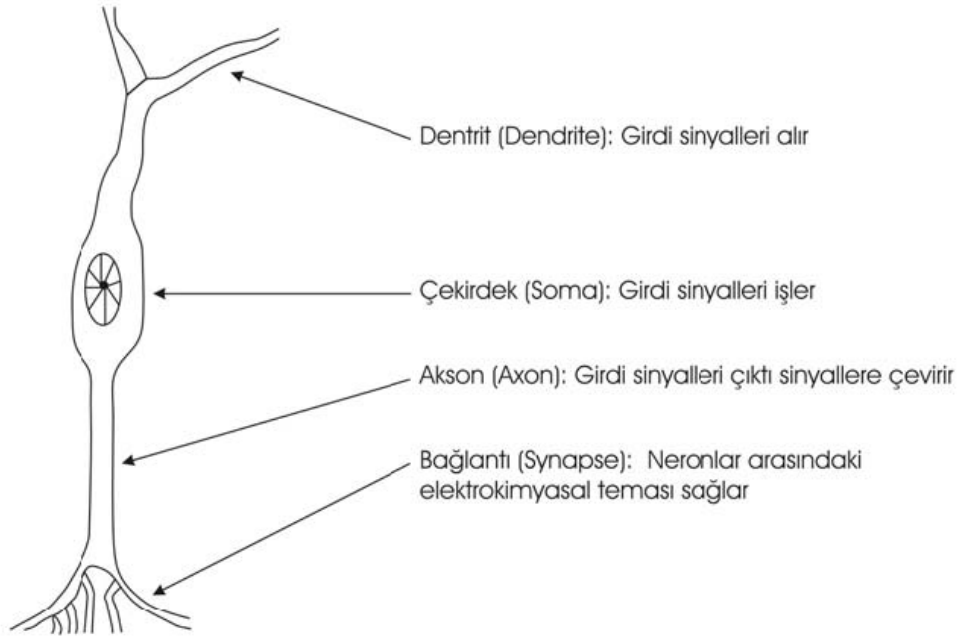
1.12 bir nöronun dört temel elemandan oluşan genel yapısını ve bu dört eleman arasındaki ilişkiyi göstermektedir (Yurtoğlu, 2005).

Şekilden de görüldüğü gibi, tüm doğal nöronlar dört temel bileşene sahiptir. Bu bileşenler biyolojik isimleri ile bilinirler: dentrit (dendrite), çekirdek (soma), akson (axon) ve bağlantı veya sinaps (synapse). Dentritler, çekirdeğin saça benzeyen uzantılarıdır ve girdi kanalları olarak işlev görürler. Bu girdi kanalları diğer nöronların sinapsları aracılığıyla girdilerini alırlar. Daha sonra çekirdek, gelen bu sinyalleri zaman içinde işler. Çekirdek, bu işlenmiş değeri bir çıktıya dönüştürdükten sonra bu çıktıyı akson ve sinapslar aracılığıyla diğer nöronlara gönderir. Tablo 1.7' de matematiksel nöral yapının biyolojik nöral yapıyla olan benzeşimi verilmektedir.

Tablo 1.7. Biyolojik sinir sistemi ve YSA sistemi arasındaki benzerlikler

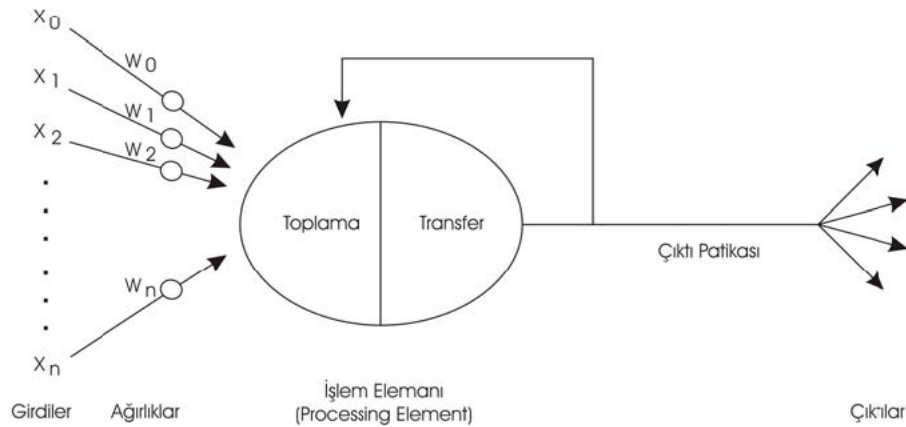
SİNİR SİSTEMİ	YSA SİSTEMİ
Nöron	İşlem elemanı
Dendrit	Toplama fonksiyonu
Hücre gövdesi	Transfer fonksiyonu
Aksonlar	Eleman çıkışı
Sinapslar	Ağırlıklar

Yapay sinir ağlarının temel işlem elemanı olan yapay nöronlar, doğal nöronların dört temel fonksiyonunu simüle ederler.



Şekil 1.12. Biyolojik Nöronun Genel Yapısı ve İşlevleri

Şekil 1.13'te girdi değerler $x(i)$ matematiksel sembolü ile gösterilmiştir ve bu gösterimde $i = 0,1,2,\dots,n$ değerlerini almaktadır. Bu girdi değerlerin her biri bir bağlantı ağırlığıyla çarpılmaktadır. Bu ağırlıklar ise $w(i)$ ile gösterilmektedir. En basit yapıda, bu çarpımlar toplanır ve bir transfer fonksiyonuna gönderilerek sonuç üretilir. Bu sonuç daha sonra bir çıktıya dönüştürülür. Bu elektronik uygulama değişik toplama fonksiyonları ve transfer fonksiyonları kullanılabilir ve farklı ağ yapılarında uygulanabilir.




Şekil 1.13. Yapay Nöronun Genel Yapısı

1.5.1.3. Aktivasyon Fonksiyonu

Aktivasyon fonksiyonu, YSA' ya lineer olmayan bir yapı kazandırmak için ara ve çıkış katmanlarında kullanılan matematiksel bir fonksiyondur. Çoğunlukla kullanılan aktivasyon fonksiyonları sıkıştırma etkisine sahiptir. YSA, aktivasyon fonksiyonu kullanmaksızın algılayıcı ağlarında olduğu gibi karmaşık problemlere (lineer olmayan) istenen yakınsamayı sağlayacak güçte bir algoritma olamamaktadır. Eğer kullanılan aktivasyon fonksiyonu lineer olursa, ağın işlemsel yapısı da lineer özellik gösterir. Genellikle MLP (Çok Katmanlı Algılayıcı) yapılarda logaritmik sigmoidal veya tanjant hiperbolik ve RBF (Radyal Tabanlı Fonksiyon) yapılarda ise Gauss fonksiyonları kullanılmaktadır. Sigmoidal fonksiyon sadece pozitif değerler üretirken, tanjant hiperbolik hem pozitif hem de negatif değerler üretir. Bu nümerik şartlanmadan dolayı tanjant hiperbolik fonksiyonların daha hızlı yakınsama eğilimi vardır. Çıkış katmanında ağ çıkış verisi eğer binari yapıda olursa (0/1) logaritmik sigmoidal fonksiyonun kullanımı daha avantajlı olabilirken, I/C kodlama durumunda ise sigmoidal fonksiyonun değişik bir formu olan "softmax" fonksiyonu daha etkin olabilir. "Softmax" fonksiyonunda amaç, çıkışların toplamını bire eşitlemektir. Böylece YSA çıkışları sınıflandırma problemlerinde aposteriori olasılıklar olarak yorumlanabilir. Radyal tabanlı aktivasyon fonksiyonlarında çıkış değerleri, girişler merkezden uzaklaştıkça monotonik olarak değişir. Bu değişim, Gauss fonksiyonunda girişler merkezden uzaklaştıkça çıkışların azalmasıyla olurken, multi-kuadratik fonksiyonda artmasıyla oluşur (Kavzoğlu, 2001).

Hangi fonksiyonun kullanılacağı YSA' nın çözmeye çalışacağı problemin şartlarına bağlıdır ve etkin bir şekilde deneme yanılma yoluyla tespit edilebilir. Şekil 1.14' te gösterildiği gibi bazı aktivasyon fonksiyonları lineer iken bazıları değildir. Geri-yayıma tabanlı öğrenme algoritmaları aktivasyon fonksiyonlarının türevli olmalarını gerektirir. Tablo 1.8 'de grafik gösterimleri yapılan aktivasyon fonksiyonlarının matematiksel yapısı verilmektedir (Özkan, 2001).



Şekil 1.14. Aktivasyon fonksiyonları; (i) sigmoid, (ii) tanjant hiperbolik, (iii) lineer, (iv) keskin sınırlayıcı, (v) gauss, (vi) çoklu-küadratik

1.5.2. Yapay Sinir Ağlarının Sınıflandırılması

Genel olarak YSA' lar birbirleri ile bağlantılı işlemci elemanlardan veya yapay nöronlardan oluşur. Nöronlar arası bağlantıların nasıl olduğu ve bağlantıların karakteri YSA' nın karakterini belirler. Sinaptik ağırlıkların, YSA' nın ulaşması istenen davranışı elde edecek şekilde güncellenmesi (dengelenmesi) veya eğitilmesi öğrenme algoritmasıyla gerçekleştirilir. YSA' lar, yapılarına ve öğrenme algoritmalarına göre sınıflandırılabilir (URL- 5, 2006).

Tablo 1.8. Aktivasyon fonksiyonlarının matematiksel yapıları

AKTİVASYON FONKSİYON TİPİ	AÇIKLAMA	MATEMATİKSEL YAPI
Keskin Sınırlayıcı		$y = \begin{cases} +1 & x \geq 0 \\ -1 & x < 0 \end{cases}$
Lineer		$y = x$
Sigmoid		$y = \frac{1}{1 + e^{-x}}$
Hiperbolik Tanjant		$y = \frac{1 - e^{-2x}}{1 + e^{-2x}}$
Gauss Tipi	c, merkez değer, r, standart sapma	$y = e^{-\frac{(x-c)^2}{r^2}}$
Çoklu-kuadratik	c, merkez değeri r, yarıçap	$y = \frac{\sqrt{r^2 + (x - c)^2}}{r}$
Softmax	k, sınıf sayısı i = 1, ..., k “n”, çıkış nöronuna gelen net giriş	$y_i = \frac{e^{n_i}}{\sum_{j=1}^k e^{n_j}}$

1.5.2.1. YSA' ların Yapılarına Göre Sınıflandırılması

Yapay sinir ağları, yapılarına göre, ileri beslemeli (feedforward) ve geri beslemeli (feedback) ağlar olmak üzere iki sınıfa ayrılmaktadır.

1.5.2.1.1. İleri Beslemeli Ağlar

İleri beslemeli bir ağda işlemci elemanlar genellikle katmanlara ayrılmıştır. İşaretler, giriş katmanından çıkış katmanına doğru tek yönlü bağlantılarla iletilir. İşlemci elemanlar bir katmandan diğer bir katmana bağlanırken, aynı katman içerisinde bağlantıları bulunmamaktadır. İleri beslemeli ağlara örnek olarak çok katmanlı algılayıcı (Multi Layer Perceptron-MLP), LVQ (Learning Vector Quantization), CMAC (Cerebellar Model Articulation Control) ağları ve GMDH (Group Method of Data Handling) ağları verilebilir.

1.5.2.1.2. Geri Beslemeli Ağlar

Geri beslemeli YSA' larda, bazı nöronların çıkışları, aynı nörona veya önceki katmanlardaki nöronlara geri beslenir. Böylece, girişler hem ileri yönde, hem de geri yönde aktarılmış olur. Bu tip sinir ağları, dinamik yapılu bir hafızaya sahiptir, diğer bir ifade ile, herhangi bir andaki çıkış, o andaki girişlerin bir fonksiyonu olduğu kadar önceki giriş ve çıkış değerlerini de yansıtmaktadır. Bu özelliğinden dolayı, bu tip ağlar, özellikle önceden tahmin uygulamaları için uygun olmaktadır. Bu ağlar çeşitli tipteki zaman serilerinin tahmininde de oldukça başarıyla kullanılmaktadır. Bu ağlara örnek olarak Hopfield ağı, SOM (Self Organizing Map), Elman ve Jordan ağları verilebilir.

1.5.2.2. YSA' ların Öğrenme Algoritmalarına Göre Sınıflandırılması

Öğrenme; gözlem, eğitim ve hareketin doğal yapıda meydana getirdiği davranış değişikliği olarak tanımlanmaktadır. YSA için öğrenme işlemi stokastik bir işlemdir. Stokastik olması ağın dayandığı çevresel şartlardan kaynaklanmaktadır (Sağiroğlu vd., 1999). Öğrenme algoritmalarına göre YSA' lar kontrollü öğrenme, kontrolsüz öğrenme ve kontrollü öğrenmenin özel bir formu olan takviyeli öğrenme olarak üçe ayrılmaktadır.

1.5.2.2.1. Kontrollü Öğrenme

Bir kontrollü öğrenme algoritması nöronlar arası bağlantı ağırlıklarını, verilen giriş veri kümesine karşılık gelen gerçek değerlerle ağ çıkışı arasındaki farka göre güncellemektedir. Böylece kontrollü öğrenme algoritması istenen çıkış sinyalini sağlamak için bir danışmana ihtiyaç duymaktadır. Bu algoritmaya örnek olarak Delta kuralı, Genelleştirilmiş Delta kuralı ve LVQ algoritması verilebilir.

1.5.2.2.2. Kontrolsüz Öğrenme

Bu öğrenme algoritmasında, istenilen çıkış değerinin bilinmesine gerek yoktur. Girişe verilen örnekten elde edilen çıkış bilgisine göre ağ, sınıflandırma kurallarını kendi kendine geliştirmektedir. Öğrenme süresince sadece giriş bilgileri verilir. YSA bağlantı ağırlıklarını

giriş paternlerini benzer özelliklere sahip gruplara ayırmak üzere ayarlar. Grossberg tarafından geliştirilen ART (Adaptive Resonance Theory) veya Kohonen tarafından geliştirilen SOM (Self Organizing Map) öğrenme algoritmaları kontrolsüz öğrenmeye örnek olarak verilebilir.

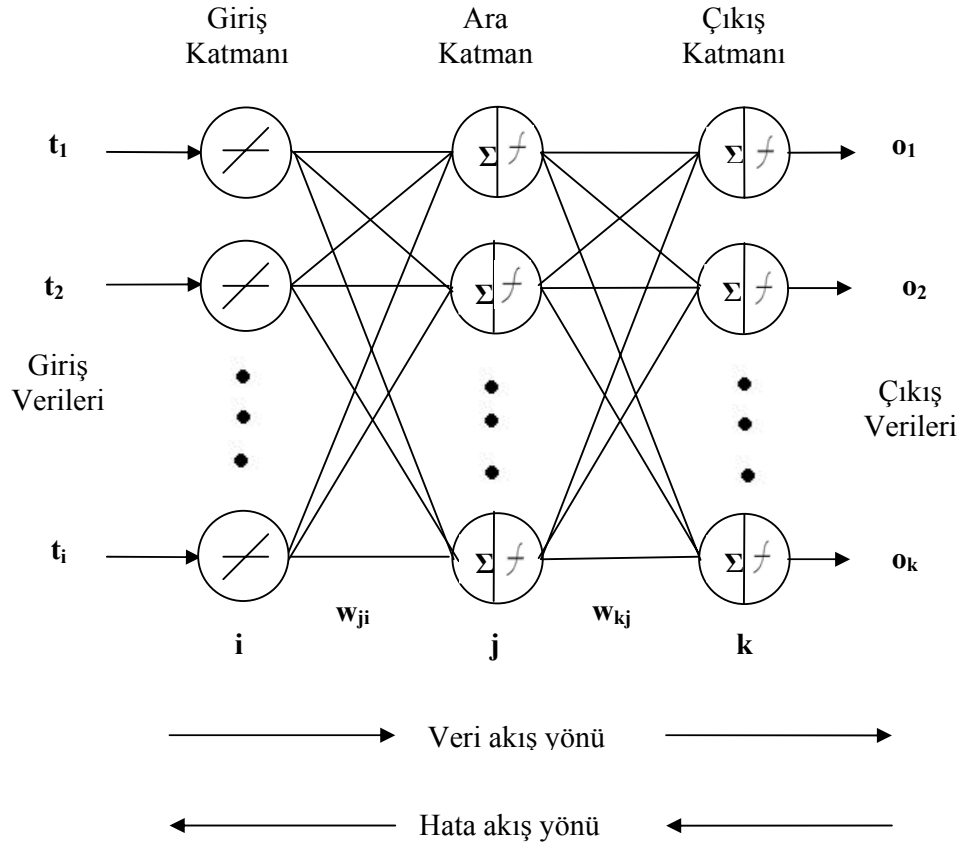
1.5.2.2.3. Takviyeli Öğrenme

Bu öğrenme kuralı kontrollü öğrenme algoritmasının özel bir formudur. Takviyeli öğrenme algoritmasında da giriş değerlerine karşı istenilen çıkış değerlerinin bilinmesine gerek yoktur. YSA' ya bir hedef verilmemekte fakat elde edilen çıkışın verilen girişe karşılık uygunluğunu değerlendiren bir kriter kullanılmaktadır. Optimizasyon problemlerini çözmek için Hinton ve Sejnowski'nin geliştirdiği Boltzmann kuralı veya Genetik algoritma (GA) takviyeli öğrenmeye örnek olarak verilebilir.

1.5.3. Çok Katmanlı Algılayıcı

Günümüzde en çok bilinen ve yaygın biçimde kullanılan yapay sinir ağı sınıflandırma yöntemi "çok-tabakalı algılayıcı sinir ağı"dır. Genel amaçlı, esnek ve çoklu tabakalar halinde organize edilmiş birimlerden (nöron) oluşan lineer olmayan modellerdir. MLP sinir ağı hemen hemen her fonksiyonu tahmin etme/yaklaştırma özelliğine sahip bir ağıdır (Şekil 1.15). Birimler genellikle "ileri-itilimli" iç bağlantılara sahiptir. İleri-itilimli bağlantının anlamı; bağlantıların herhangi bir şekilde döngü oluşturmamasıdır. MLP sinir ağının üstünlüğü, nöronlarda kullanılan lineer olmama yeteneğinden kaynaklanmaktadır.

Bu tez çalışmasında, kontrollü öğrenme algoritmalarından geri yayılma algoritması, çalışma bölgesine ait çok spektrumlu dijital uydu görüntüsünün sınıflandırılmasında kullanılmıştır. Elde edilen sınıflandırma sonuçları hem Maksimum Olabilirlik hem de Bulanık Mantık yöntemiyle karşılaştırılmıştır.



Şekil 1.15. Çok katmanlı algılayıcı ağ yapısı

1.5.3.1. Geri Yayılım Öğrenme Algoritması

Geri yayılım öğrenme algoritması, iteratif gradiyent azaltım algoritmasıdır. Bu algoritma, hataları çıkıştan girişe geriye doğru azaltmaya çalışmasından dolayı geri yayılım ismini almıştır. Tipik çok katlı geri yayılım ağı, daima; bir giriş katmanı, bir çıkış katmanı ve en az bir ara katmana sahiptir. Ara katman sayısında teorik olarak bir sınırlama yoktur. Fakat genel olarak bir veya iki tane bulunur. Patern sınıflandırma problemlerinde ara katman sayısının maksimum üç olabileceğini gösteren çalışmalar da bulunmaktadır. Geri yayılım, çok katmanlı algılayıcı ağların eğitiminde en çok kullanılan temel bir algoritmadır. Giriş veri vektörü ağın öğrendiği veri kümesi olup çıkış vektörü, ağın üretmesi beklenen gerçek çıkış değerleridir. Eğitimin amacı da istenen çıkış değerleriyle ağın ürettiği çıkış değerleri arasındaki farktan kaynaklanan hatanın minimize edilmesidir.

Geril yayılım algoritmasının formülasyonundaki notasyon aşağıda verilmektedir (Sağırođlu vd., 1999):

- i ; giriş katmanı işlemci eleman indeksi,
 - j ; ara katman işlemci eleman indeksi,
 - k .; çıkış katmanı işlemci eleman indeksi,
 - t_i ; giriş vektörü,
 - d_k ; istenen (hedef) çıkış vektörü,
 - o_k gerçek (ađın ürettiđi) çıkış vektörü,
 - o_j ara katman çıkış vektörü,
 - w_{kj} çıkış ve ara katmanlar arasındaki ađırlıklar,
 - w_{ji} ara ve giriş katmanları arasındaki ađırlıklar,
 - f ; her bir işlemci elemanın aktivasyon fonksiyonu,
 - P ; eğitim vektörlerinin toplam sayısı.
- Tek bir eğitim verisi giriş vektörü için olan hata deđeri;

$$E = \frac{1}{2} \sum_k (d_k - o_k)^2 \quad (6)$$

Çıkış katmanı işlemci elemanı k tarafından üretilen o_k ađ çıkış deđeri işlemci eleman k ' ya gelen ađırlıklandırılmış net toplamın aktivasyon fonksiyon deđeridir.

$$o_k = f(\text{net}_k) = f\left(\sum_j (w_{kj} o_j)\right) \quad (7)$$

Burada net_k ara ve çıkış katmanları arasındaki ađırlıklarla ara katman çıkış deđerlerinin iç çarpımlarının toplamıdır. Hatayı minimize etmek için w_{kj} ađırlık deđerindeki bir iterasyondan diđerine olan deđişim E hata deđerinin ađırlıklara göre olan türevleriyle orantılı olmalıdır. Yeni ađırlık deđerleri;

$$w_{kj}(m+1) = w_{kj}(m) - \alpha \sum \frac{\partial E(m)}{\partial w_{kj}(m)} \quad (8)$$

dir. Öğrenme oranı α , her bir iterasyonda minimum hataya doğru olan adım yüzdesidir. Zincir kuralı kullanılarak;

$$\frac{\partial E}{\partial w_{kj}} = \frac{\partial E}{\partial o_k} \frac{\partial o_k}{\partial net_k} \frac{\partial net_k}{\partial w_{kj}} \quad (9)$$

elde edilir. (9) eşitliğindeki son çarpan,

$$\frac{\partial net_k}{\partial w_{kj}} = \frac{\partial \left(\sum_j w_{kj} o_j \right)}{\partial w_{kj}} = o_j \quad (10)$$

ara katman işlemci eleman çıkışıdır:

$$\delta_k = -\frac{\partial E}{\partial o_k} \frac{\partial o_k}{\partial net_k} = -\frac{\partial E}{\partial net_k} \quad (11)$$

E değeri için (6) eşitliği kullanılarak;

$$\frac{\partial E}{\partial o_k} = \frac{\partial \left(\frac{1}{2} \sum_k (d_k - o_k)^2 \right)}{\partial o_k} = -(d_k - o_k) \quad (12)$$

elde edilir. (11) eşitliğindeki ikinci çarpan çıkış işlemci elemanı k'da kullanılan aktivasyon fonksiyonunun türevidir:

$$\frac{\partial o_k}{\partial net_k} = f'(net_k) \quad (13)$$

Bunun için;

$$\delta_k = (d_k - o_k) f'(net_k) o_j \quad (14)$$

dir. Ağırlık w_{kj} terimi için olan toplam değişim;

$$\begin{aligned}
\Delta w_{kj} &= \alpha \delta_k o_j \\
&= \alpha (d_k - o_k) f'(net_k) o_j
\end{aligned} \tag{15}$$

dir. Ağırlık değişim formülünü belirlemek için hata çıkış katmanından girişe doğru yayılmalıdır. Ara katmadaki hata terimi çıkış katmanındaki bütün değişimlerin toplamından hesaplanır.

Bu ağırlık w_{ji} nin değişim formülü daha karmaşık bir yapıda ortaya çıkar:

$$\Delta w_{ji} = -\alpha \frac{\partial E}{\partial w_{ji}} = -\alpha \frac{\partial E}{\partial o_j} \frac{\partial o_j}{\partial net_j} \frac{\partial net_j}{\partial w_{ji}} = -\alpha \frac{\partial E}{\partial o_j} \frac{\partial o_j}{\partial net_j} o_j \tag{16}$$

Giriş katmanının çıkış değeri o_i basitçe eğitim vektörü t_i dir. Böylece;

$$\begin{aligned}
\Delta w_{ji} &= \alpha \left(-\frac{\partial E}{\partial o_j} f'(net_j) \right) t_i \\
&= \alpha \delta_j t_i
\end{aligned} \tag{17}$$

$\partial E/\partial o_k$ dan farklı olarak $\partial E/\partial o_j$ doğrudan değerlendirilemez. Çünkü gerçek ve istenen çıkış değerlerinin bir fonksiyonu değildir. Ara katman işlemci eleman hatasındaki (E) bu değişim, çıkış katmanındaki bütün değişimlerin toplamından elde edilmelidir. Böylece;

$$-\frac{\partial E}{\partial o_j} = -\sum_k \left(\frac{\partial E}{\partial net_k} \frac{\partial net_k}{\partial o_j} \right) \tag{18}$$

$$= \sum_k \left(-\frac{\partial E}{\partial net_k} \frac{\partial \left(\sum_j (w_{kj} o_j) \right)}{\partial o_j} \right) \tag{19}$$

$$= \sum_k \left(-\frac{\partial E}{\partial net_k} w_{kj} \right) \tag{20}$$

elde edilir.

$$-\frac{\partial E}{\partial net_k} = \delta_k = (d_k - o_k) f'(net_k) \quad (21)$$

bulunur. Ara katmandaki δ terimi δ_j , çıkış katmanında hesaplanan δ_k ya bağlı olarak açıklanabilir:

$$\delta_j = f'(net_j) \sum_k (\delta_k w_{kj}) \quad (22)$$

Girişten ara katmana doğru ağırlıklar için olan değişim terimi;

$$\Delta w_{ji} = \alpha f'(net_j) \sum_k (\delta_k w_{kj}) t_i \quad (23)$$

dir. Hata, önceki katmana δ_k terimi kullanımıyla yayılmıştır, (m+1) iterasyonu için bütün ağırlık güncelleme formülü, m iterasyonundaki değerlerin kullanımıyla;

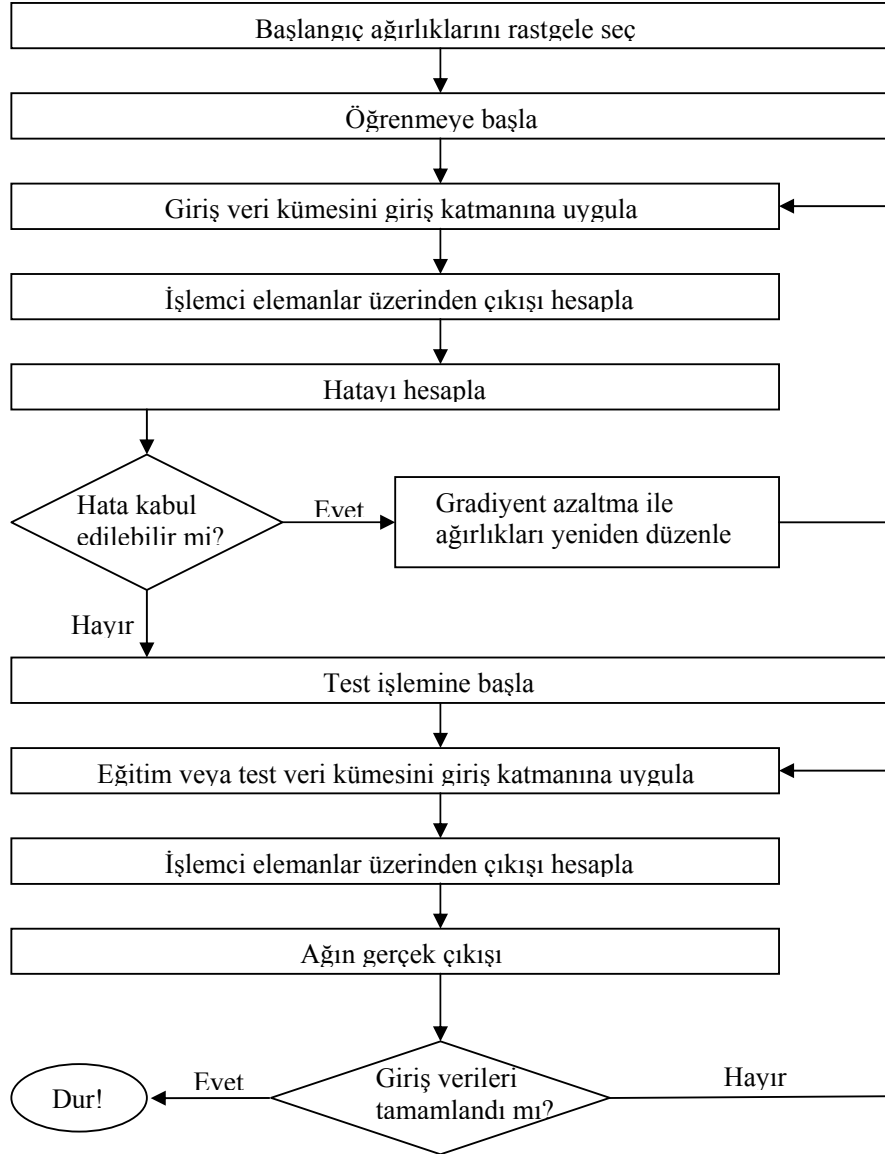
$$\begin{aligned} w_{kj}(m+1) &= w_{kj}(m) + \alpha \sum_j (\delta_k o_j) \\ &= w_{kj}(m) + \alpha \sum_j ((d_k - o_k) f'(net_k) o_j) \end{aligned} \quad (24)$$

ve

$$\begin{aligned} w_{ji}(m+1) &= w_{ji}(m) + \alpha \sum_i (\delta_j t_i) \\ &= w_{ji}(m) + \alpha \sum_i \left(f'(net_j) \sum_k ((d_k - o_k) f'(net_k) w_{kj}(m)) t_i \right) \end{aligned} \quad (25)$$

dir. Tek ara katman için üretilen eşitlikler basitçe aynı mantık çerçevesinde daha fazla ara katman için genişletilebilir. w_{kj} ' den önce her bir ağırlık kümesi önceki ağırlık kümesinin sonucu olan δ' ya bağlı olarak açıklanan bir fonksiyon tarafından güncellenir. Her bir eğitim vektörü ağa girildikçe her bir işlemci elemandaki δ terimi toplanır. Gerçek ve

istenen çıkış değerleri arasındaki hatada toplanır. Eğitim döngüsü (iterasyon veya epok) tamamlandığında eğer bu hata önceden belirlenen kritik hata değerinden büyükse ağırlıklar yukarıda gösterildiği gibi δ terimi kullanılarak güncellenir ve eğitim süreci devam eder. Bu algoritmanın akış şeması Şekil 1.16 'da verilmiştir (Erlar, 1999).



Şekil 1.16. Geri-yayılım akış şeması

Ağırlıkların güncellendiği (24) eşitliğindeki türevi ölçekleyen öğrenme oranı ağ eğitimine başlamadan önce belirlenmelidir.

Öğrenme oranı: Bağlantıların ağırlık değerlerindeki değişimin miktarını tanımlar. Bu oranı yüksek alma, değişimin miktarını artıracaktır. Düşük alınır ise, değişim miktarı azalacaktır.

Momentum Katsayısı: Toparlanma oranını hızlandırmak için en çok kullanılan sezgisel yöntemlerden biri, momentum faktörünün kullanımıdır. Bu faktör, ağıın daha hızlı toparlanmasına yardım eder. Temel olarak, daha önceki değişimin bir kısmını halihazırdaki değişime eklemeye dayanır. Başlıca düşünce, öğrenme esnasında ağıın salınımını önlemektir.

Öğrenme oranının ağıın yakınsama süresine önemli bir etkisi vardır. Eğer çok küçük seçilirse kabul edilebilir bir çözüm için çok fazla sayıda adıma ihtiyaç olacaktır. Tersini durumda ise hatanın hedeflenen giriş değerine ulaşmasını engelleyecek bir şekilde ağıın salınım yapmasına neden olacaktır. Bu sakıncaları ortadan kaldırmak için momentum parametresi kullanımı veya öğrenme sırasında adaptif parametre seçimi gibi birçok araştırma yapılmıştır.

Bütün gradiyent azaltım algoritmalarında olduğu gibi geri-yayıma algoritması da amaç olan global minimumu bulmayı garanti etmemektedir. Eğitim sırasında ağ bulunduğu konumdan daha düşük hatalı bir konuma doğru en kestirme yolu kullanır.

Eğer ağ hata uzayında bir lokal minimum noktasına rastlarsa o noktaya takılıp global minimum noktasına ulaşmayabilir. Ayrıca sistem iki nokta arasında sıkışarak salınım da yapabilir. Bu problemleri çözmek için ağırlıkların güncellenmesinde geliştirilen (5.19) eşitliğine bir önceki iterasyonda hesaplanan değişim miktarının bir parçası, $\mu\Delta w_{kj}(m)$ eklenebilir. Böylece ağırlıkların güncellenmesi için yeni formüller;

$$w_{kj}(m+1) = w_{kj}(m) + \sigma \sum^p (\delta_k o_j) + \mu \Delta w_{kj}(m) \quad (26)$$

ve

$$w_{ji}(m+1) = w_{ji}(m) + \sigma \sum^p (\delta_j t_i) + \mu \Delta w_{ji}(m) \quad (27)$$

olarak elde edilir. Eklenen bu itme etkisi (f_i), ağıın lokal minimuma takılıp kalmasını engeller. Öğrenme oranı parametresi gibi momentum parametresi de, μ , eğitim işleminin başlangıcında belirlenmelidir. Momentum parametresi sabit olarak seçilebileceği gibi adaptif bir yapıda da kullanılabilir. Momentum parametresi alçak-geçişli bir filtre etkisi göstererek hata yüzeyindeki küçük salınmaları ve özellikleri baskılar. Momentum parametresi ağıın kararlılığını bozmaksızın daha büyük öğrenme katsayısı kullanmayı sağlar. Ayrıca istikrarlı ve kararlı bir öğrenme durumunda yakınsamayı ivmelendirici bir etki yapar (Özkan, 2001).

1.5.4. YSA ile Görüntü Sınıflandırma

YSA, verilen hedef değerlerine göre belirli bir performans kriterini sağlayarak öğrenen, dağılımdan bağımsız lineer olmayan bir fonksiyondur. YSA, son yıllarda popüler olan parametrik olmayan bir sınıflandırma yaklaşımıdır. YSA' nın diğer sınıflandırma algoritmalarından farkı, (i) karar sınırlarının sınıfları temsil eden eğitim verilerine uygulanan deterministik bir kuralla sabit olmaması (tesadüfi), (ii) farklı kaynaklardan elde edilen değişik verilerin kolaylıkla birlikte kullanılabilmesi ve (iii) herhangi bir dağılım kabulünü gerektirmemesidir. Kontrollü öğrenmede karar sınırları, hedef değerlerle ağıın ürettiği değerlerin arasındaki farktan kaynaklanan hatanın belirli bir kurala göre iteratif olarak minimize edilmesiyle belirlenir. Bu anlamda YSA algoritması kontrolsüz kümeleme algoritmalarına benzemektedir. Belirtilen avantajlarına karşın YSA bazı sınırlamalara sahiptir. Dış ve iç sınırlamalar olarak ele alınabilecek bu sınırlamalardan; (i) dış sınırlamalar, giriş verisinin karakteristikleri ve çalışma ölçeği, (ii) iç sınırlamalar ise, uygun ağ yapısının seçimi, ağ parametrelerinin başlangıç değerlerinin belirlenmesi, iterasyon sayısı, aktivasyon fonksiyon tipi ve öğrenme oranının belirlenmesi gibi sınırlamaları içermektedir (Kavzoğlu, 1999). Bu sınırlamaların sonucu olarak YSA davranışını yorumlamak güçleşmektedir.

Eğitim veri kümesindeki paternleri kullanarak karar sınırlarının belirlenmesi işlemi öğrenme veya eğitim olarak adlandırılır. İstatistiksel sınıflandırma algoritmalarında karar fonksiyonlarının temelini oluşturan istatistiksel varsayımlara ait parametrelerin belirlenmesi gerekir. Bu parametreler eğitim veri kümesi kullanılarak belirlenir. YSA tabanlı sınıflandırma algoritmalarının en belirgin özellikleri herhangi bir istatistiksel kabul gerektirmemeleridir. Kontrollü öğrenme işleminde, öğrenmeyi temsil eden bağlantı ağırlık

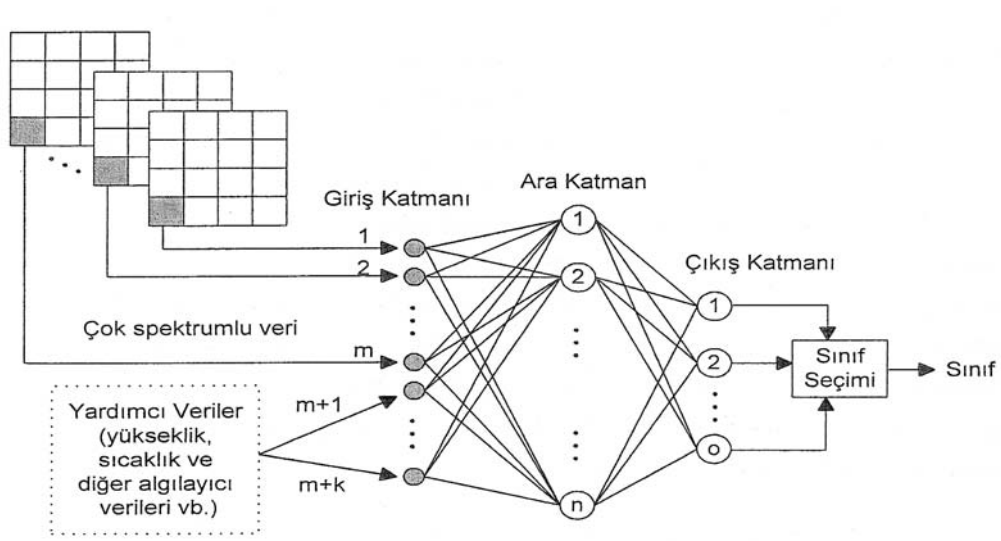
değerleri, iteratif bir şekilde ağıın ürettiği çıkışların hedef çıkışlarla karşılaştırılmalarıyla elde edilen belirli bir hata değerinin minimize edilmesiyle güncellenirken, kontrolsüz öğrenme işleminde, ağırlık değerlerinin güncelleştirilmesi (öğrenme, eğitim) giriş paternine en büyük benzerlik değerini üreten işlemci elemanın aktiflenmesiyle gerçekleştirilmektedir.

1.5.4.1. Ön İşleme

Ön işlemede amaç, YSA sınıflandırma performansını arttırmak için özellik çıkartımıdır. Bu amaçla ana-bileşen dönüşümüyle boyutluluk azaltılabilir veya piksel verileriyle birlikte veya sadece doku, moment gibi uzaysal bilgiler kullanılabilir. Bununla beraber, öncül işlemeyle elde edilen bilgilerle ağıın hız ve performans kapasitesi artabilmesine rağmen işlenmemiş orijinal verinin kullanılması ağı daha uygulanabilir yapmaktadır. Örneğin bir grup piksel üzerinden hesaplanan tek bir doku bilgisi kullanılabileceği gibi, bunun yerine bu bilginin çıkarıldığı orijinal piksel grubunun işlenmesi daha esneklik kazandıracaktır.

1.5.4.2. Ağ Girişinin Kodlanması

Birçok istatistiksel sınıflandırma algoritmasında olduğu gibi en temel ve basit veri giriş şekli, piksel paternlerinin tek tek kullanılmasıdır. İlgili patern için özellik (spektral kanal) sayısı kadar giriş katmanı işlemci elemanın kullanılması en yaygın kullanılan veri giriş tekniğidir. Şekil 1.17' de her bir spektral kanala bir giriş nöronu atanarak oluşturulan giriş kodlaması gösterilmektedir.



Şekil 1.17. YSA' da örnek giriş kodlaması

Giriş verileri, spektral bilgiler olabileceği gibi uzaysal bilgiler de olabilir. Uzaysal bilgiler spektral bilgilerle beraber kullanılabilir. Uzaysal bilgi doku ölçüm değeriyle (varyans vb.) temsil edilebileceği gibi doğrudan piksel değerleriyle de ifade edilebilir.

MLP yapısında giriş katmanındaki işlemci elemanlar ara katman işlemci elemanlarıyla bütünüyle bağlantılı oldukları için, giriş verisinin sıralaması önemli olmayıp veri formatı önemlidir. MLP yapılarında matematiksel bir zorunluluk olmamasına rağmen özellikle sigmoid veya tanjant hiperbolik (TANH) aktivasyon fonksiyonu kullanılarak verinin [0 1] veya [-1 1] aralığına çekilmesi işlemsel etkinliği arttırabilmektedir. Böylece YSA'nın yakınsama değeri iyileşmekte ve yakınsama hızı da artmaktadır. Ölçeklemenin aynı aralıkta olması gerekmektedir. Sigmoid ve TANH fonksiyonlarının sıkıştırma etkisi olduğu için giriş verisinin bu şekilde ölçeklenmesi, ağ performansını ve yakınsama hızını olumlu yönde etkileyebilmektedir (Kavzoğlu, 2001).

1.5.4.3. Ağ Çıkışının Kodlanması

YSA çıkışlarının sınıflandırma problemleri için en doğal kodlanma şekli her bir sınıf için bir işlemci eleman kullanımınıdır. Genellikle istenen çıkış değerlerine, paternin ait olduğu sınıfı temsil eden işlemci eleman için yüksek, diğerleri için düşük değerler atanır. Örneğin pikselin ait olduğu sınıfa karşılık gelen işlemci elemana 1 ve diğer işlemci

elemanlara 0 atanabilir. 1/0'dan farklı olarak 0.9/0.1 gibi veya 0.99/0.01 gibi değerlerde atanabilir.

1.5.4.4. Sınıfların Çıkarılması

Her bir sınıf için ayrı bir işlemci eleman kullanılmasıyla pikseller en yüksek çıkış değerini aldığı işlemci elemanın temsil ettiği sınıfa atanır.

YSA çıkış değerleri, sınıflandırma güven ölçütü olarak değerlendirilebilir. Yüksek değer, ilgili pikselin o sınıfa yüksek bir doğrulukla ait olduğunu ifade eder. Literatürde yapılan bir çalışmada, bu değerlerin sınıf üyeliklerini gösterdiği belirtilmiştir.

1.5.4.5. Ağ Topolojisi

YSA yapılarında giriş ve çıkış katmanlarındaki işlemci eleman sayıları, veri boyutu ve istenen sınıf sayısı gibi dış etkenlere göre belirlenirken, ara katmanlardaki elemanlar deneme yanılma yoluyla belirlenmektedir. YSA'nın teorik kapasitesi ara katman işlemci eleman sayısına bağlıdır. Örneğin tek ara katmanlı bir yapı, ara katmanın üreteceği yarı-düzlem karar sınırları üzerinde bir "ve" operatörü gibi davranır. Gerçek karar sınırları, ara katman işlemci eleman sayısına eşit veya daha az sayıda kenarlı olan konveks poligonlar veya sınırlanmamış konveks bölgelerdir. Böylece ara katman işlemci eleman sayısının artması, ağı, karar uzayının kategorize edilmesinde daha esnek yapmaktadır. Fakat ağın çok esnek olması da aşırı eğitime, yani ağın veriyi öğrenmeden ezberlemesine neden olabilir. Bu durumda ağ, eğitim verisi dışında kalan görüntünün diğer bölümleri için uygulanabilir olmamaktadır. Ara katman optimal işlemci eleman sayısı probleme bağlı olup deneyimlerle belirlenmesi gerekir (Özkan, 2001).

YSA kullanıcıları, en uygun ara katman sayısının hesabı için yapmış oldukları deneme-yanılma metodlarının sonucunda kurallar oluşturmuşlardır (Tablo 1.9). Ancak bu bulgularda kullanılabilecek kabul edilmiş teorik bir yaklaşım yoktur. Tabloda N_i giriş katman sayısını, N_o çıktı katman sayısını, N_p toplam eğitim örneği sayısını ve r ise 5 ile 10 arasında değişen sabit bir değeri ifade etmektedir.

Tablo 1.9. En uygun ara katman sayısının hesaplanmasında araştırmacıların önerileri

Bulgu	Kaynak	En uygun katman sayısı
$2N_i$ ya da $3N_i$	Kanellopoulos <i>et al.</i> (1997)	16 ya da 24
$3N_i$	Hush (1989)	24
$2N_i + 1$	Hecht-Nielsen (1987)	17
$2N_i / 3$	Wang (1994)	6
$(N_i + N_o) / 2$	Ripley (1993)	8
$N_p / [r(N_i + N_o)]$	Garson (1998)	15-30
$\frac{2 + N_o x N_i + \frac{1}{2} N_o (N_i^2 + N_i) - 3}{N_i + N_o}$	Paola (1994)	21

1.5.4.6. YSA'da Eğitim

MLP ağlarının eğitilmesi için kullanılan geri yayılım algoritmasında eğitim, ya paternlerinin ağa bireysel girişlerinden elde edilen hataya göre ya da paternlerin ağa bütünüyle girildiklerinde elde edilen toplam hataya dayanarak gerçekleştirilmektedir.

Genel olarak YSA eğitimi, aşağıdaki aşamaları içermektedir:

1. Eğitim ve buna karşılık gelen çıkış verilerinin belirlenmesi.
2. Ağ topolojisinin belirlenmesi (giriş, ara ve çıkış katman sayıları).
3. Ağırlık başlangıç değerlerinin atanması. Bu değerler rasgele atanır. Aksi takdirde, ağın dağıtılmış bilgisini içeren farklı ağırlık değerlerine ulaşmak mümkün olamamaktadır.
4. Öğrenme ve momentum oranı gibi gereken ağ parametrelerinin belirlenmesi. Bu parametrelerin optimum değerlerinin deneme-yanılma yoluyla belirlenmesinin yanında adaptif yöntemlerde kullanılabilir.
5. Çıktı kodlamasının belirlenmesi.

1.6. Bulanık Mantık Kavramı

Modelleme, sonuç çıkarma, hesaplama için kullanılan geleneksel yöntemlerin çoğu keskindir, sayısaldır ve tam doğrudur. Buna karşın gerçek durumlar birçok bakımdan belirsizdir ve bulanıktır. Bilgi eksikliğinden dolayı bir sistemin gelecekteki durumu

tamamiyle bilinemeyebilir. Bundan dolayı dış dünyada yapılan çalışmalar için iki problem söz konusudur. (1) Gerçek durumlar çoğu zaman keskin ve sayısal değildir, ve onlar kesin olarak tanımlanamazlar. (2) Gerçek bir sistemin tanımlanması bir insanın anlık tanımlama ve anlamalarından çok daha fazla bilgi gerektirir. Bu gibi durumlarda insan kararları dilsel bir şekilde ifade edilebilen belirsiz ve duyarsızlıklara dayanır. Bulanık mantık bu karar verme işlemlerini modellemede kullanılan yöntemlerden biridir (Samadzadegan vd., 2002).

Bulanık mantık 1965 yılında Lotfi A. Zadeh tarafından ortaya atılmıştır. Esas olarak, bulanık mantık doğru/yanlış, evet/hayır, yüksek/alçak gibi geleneksel değerler arasında tanım yapabilmek için geçiş değerlerine izin veren çok değerli bir mantıktır. Oldukça uzun ya da çok hızlı gibi sözel terimler matematiksel olarak formüle edilebilir ve bilgisayarlar tarafından işlenebilir (Hellman, 2004).

Bulanık mantık bir tür makine zekasıdır. Bilgisayar bilgiyi yalnızca 'doğru' ya da 'yanlış' olarak algılayıp 1 ve 0'dan oluşan dizgeler halinde işlem yapar. İnsansa bilgisayarın tersine kısmi doğrular ya da yanlışlar üzerinden duyularını ve tecrübelerini kullanarak işlemi gerçekleştirir. Bilgisayar için sıcak ya da soğuk vardır ama insan için soğuk, serin, normal, ılık ya da sıcak olabilir. Bilgisayarın sıcak ve soğuk içinde serini de tanıyabilmesi için bulanık mantık (fuzzy logic) kullanılır. Bulanık mantık, bilgisayarın insan gibi davranmasını ve 'akıllı' olmasını sağlar (Demirel, 1999).

Bulanık mantık Zadeh' in 1965' deki orjinal makalesinde yayımlanmasından sonra belirsizlik içeren sistemlerin incelenmesi yeni bir boyut kazanmıştır. 1965 yılında ortaya atılmasına rağmen bulanık küme kavramı ancak 1970' li yılların ikinci yarısından sonra kullanılmaya başlanmıştır. 1980'li yılların ikinci yarısından sonra Japonların ürünlerinde bulanık mantığı kullanmalarıyla da hız kazanarak, günümüzdeki doruk noktasına ulaşmıştır. Artık hemen her alanda bulanık mantık uygulamalarına rastlamak mümkündür (Altaş, 1999). Bulanık mantığın jeodezideki uygulama alanlarından bazıları coğrafi bilgi sistemlerinde veri analizlerinde, deformasyon analizlerinde, taşınmaz malların değerlendirilmesinde ve parametre kestirimi gibi pek çok alanda kullanılmaktadır (Akyılmaz, 2003).

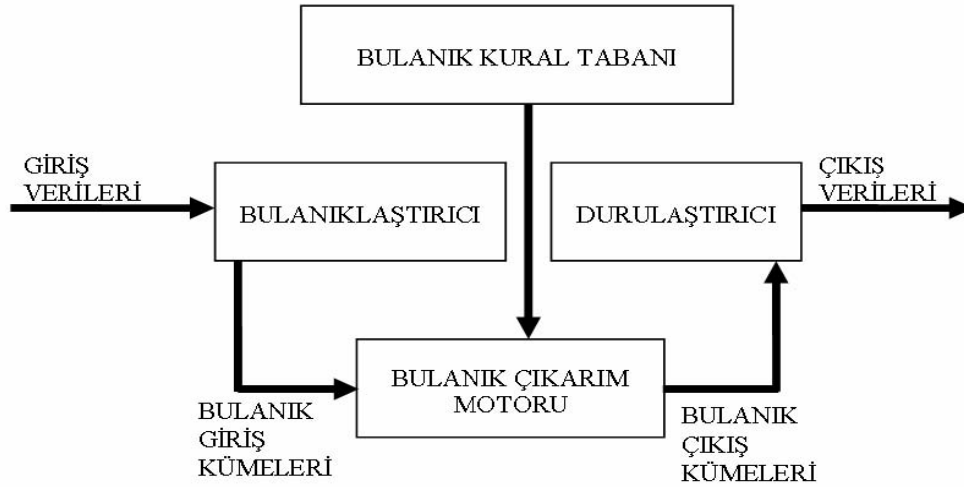
1.6.1. Bulanık Model

Bulanık modeller oluşturulurken değişik formlarda üyelik fonksiyonları seçilebilir. Yaygın olarak kullanılan üyelik fonksiyonları olarak üçgen, yamuk, Gauss eğrisi, sigmoid

fonksiyonu vb. kullanılmaktadır. Bulanık sistemler genel olarak, mevcut verilerden seçilen girdi değişkenlerinden çıktı değişkenlerinin elde edilmesini sağlamak amacıyla bulanık küme ilkelerini kullanan sistemlerdir. Bulanık sistemlerin en büyük avantajı insan deneyimlerinin ve sözel verilerin bulanık modele katılması ile çözüme ulaşılmasıdır. Bulanık model (bulanık çıkarım sistemi), bulanık Eğer İse kuralları adı verilen bulanık kurallara dayanan sistemlerdir. Bulanık modelin temeli, bulanık Eğer İse kurallarından anlaşılacağı üzere öncül ve soncul kısımlardan oluşmaktadır. Öncül kısımda sonuca sebep olan giriş değişkenleri ve bunlar arasındaki mantıksal ilişkiler, soncul kısımda ise bu giriş değişkenlerine bağlı olarak ortaya çıkan sonuç değişkenleri yer alır. Genel olarak bulanık kurallar aşağıdaki formdadır;

Kural 1: Eğer $x = A1$ ve $y = B1$ İse $z = N1$ Kural 2: Eğer $x = A2$ ve $y = B2$ İse $z = N2$

Burada x ve y öncül kısımdaki girdi değişkenlerince tanımlanan koşulları z ise soncul kısımdaki çıktı değişkenlerince tanımlanan sonuçları ifade eder (Yılmaz ve Arslan, 2005). Şekil 1.18' de genel bir bulanık model sisteminin yapısı gösterilmektedir.



Şekil 1.18. Bulanıklaştırma – durulaştırma birimli bulanık sistem

1. *Genel Bilgi Tabanı Birimi:* İncelenecek olayın etkilendiği girdi değişkenlerini ve bunlar hakkındaki tüm bilgileri içerir. Genel veri tabanı denmesinin sebebi buradaki bilgilerin sayısal ve/veya sözel olabilmesidir.
2. *Bulanıklaştırıcı:* Sayısal girdi değerlerini sözel olarak nitelendirilmiş bulanık kümelerdeki üyelik derecelerine atayan bir işlemcidir.

3. *Bulanık Kural Tabanı Birimi*: Veri tabanındaki girişleri çıkış değişkenlerine bağlayan mantıksal EĞER – İSE türünde yazılabilen kuralların tümünü içerir. Bu kuralların yazılmasında sadece girdi verileri ile çıktılar arasında olabilecek tüm ara (bulanık küme) bağlantıları düşünülür. Böylece, her bir kural girdi uzayının bir parçasını çıktı uzayına mantıksal olarak bağlar. İşte bu bağlamaların tümü kural tabanını oluşturur.
4. *Bulanık Çıkarım Motoru Birimi*: Bulanık kural tabanında giriş ve çıkış bulanık kümeleri arasında kurulmuş olan parça ilişkilerin hepsini bir arada toplayarak sistemin bir çıkışlı davranmasını temin eden işlemler topluluğunu içeren bir mekanizmadır. Bu motor her bir kuralın çıkarımlarını bir araya toplayarak tüm sistemin girdiler altında nasıl bir çıktı vereceğinin belirlenmesine yarar.
5. *Durulaştırıcı*: Bulanık işlemler sonucu elde edilen bulanık çıkarım sonuçlarını keskin sayısal çıkış değerlerine dönüştürür.
6. *Çıktı Birimi*: Bilgi ve bulanık kural tabanlarının bulanık çıkarım motoru vasıtası ile etkileşimi sonunda elde edilen çıktı değerlerinin topluluğunu belirtir.

Bulanık mantık ile modellemenin tercih edilmesinin nedenleri özetlenecek olursa (URL- 3, 2006);

- Bulanık mantığın anlaşılması kolaydır. Bulanık mantığın dayandığı matematiksel teori basittir. Bulanık mantığı çekici kılan şey yaklaşımının doğallığı ve kompleks ya da karmaşıklıktan uzak olmasıdır.
- Bulanık mantık esnektir.
- Eksik ya da yetersiz verilerle işlemler yapılabilmektedir.
- Bulanık mantık karmaşık lineer olmayan fonksiyonları modelleyebilir. ANFIS gibi uyarlanabilir teknikler yardımı ile herhangi bir girdi ve çıktı veri kümelerini eşleştirerek bulanık modeller oluşturulabilir.
- Bulanık mantık ile uzman kişilerin görüş ve tecrübelerinden yararlanılır.
- Bulanık mantık sıradan insanların günlük işlerinde kullandığı dili kullanır. Bu da bulanık mantığın en büyük avantajıdır.

1.6.2. Bulanık Modelleme Çeşitleri

Bulanık mantık ile yaygın olarak kullanılan başlıca modellemeler; Mamdani ve Takagi – Sugeno tipi bulanık modellemelerdir.

1.6.2.1. Mamdani Tipi Bulanık Modelleme

Mamdani tipi bulanık model çok kolay oluşturulur, insan davranışlarına çok uygundur. Bu nedenle çok yaygın bir kullanıma sahiptir ve diğer bulanık mantık modellerin temelini oluşturur. İlk defa bir buhar motorunun insan tecrübelerinden elde edilen sözel kontrol kuralları yardımıyla kontrolü amacıyla kullanılmıştır. Bu modelde hem girdi değişkenleri hem de çıktı değişkeni kapalı formdaki üyelik fonksiyonları ile ifade edilir (Yılmaz ve Arslan, 2005).

Mamdani tipi bir bulanık model aşağıdaki 5 adımda oluşturulur (URL- 4, 2006);


- a) Girdilerin bulanıklaştırılması: öncül kısımdaki bütün bulanık ifadeleri kullanarak girdi değişkenlerine ait 0 ile 1 arasında değişen üyelik derecelerinin belirlenmesi.
- b) Bulanık mantık işlemlerini kullanarak kural ağırlıklarının belirlenmesi
- c) Bulanık küme mantıksal işlemcilerin (ve, veya) uygulanması
- d) Sonuçların toplanması: her bir kuralın çıktısını temsil eden bulanık kümelerin birleştirilmesi
- e) Durulaştırma: tek bir sayıya dönüştürülmüş toplam bulanık küme sonuçlarının durulaştırılması.

Şekil 1.19' da x ve y gibi sayısal iki değişkeni içeren iki kurallı bir Mamdani tipi bulanık modelde z çıkış değerinin c_i bulanık küme fonksiyonlarından nasıl hesaplandığı gösterilmektedir.

Kural 1: Eğer $x = A1$ ve $y = B1$ ise $z = C1$

Mamdani tipi bulanık modelin avantajlarını özetlemek gerekirse

- i. Modelin oluşturulması basittir.
- ii. Diğer bulanık mantık modellemenin temelini oluşturur.
- iii. İnsan davranış ve duyularına uygundur.



Şekil 1.19. Bulanık VE ve VEYA işlemleri için sırasıyla minimizasyon ve maksimizasyon operatörlerini kullanan Mamdani tipi bulanık çıkarım sistemi

1.6.2.2. Takagi – Sugeno Tipi Bulanık Modelleme

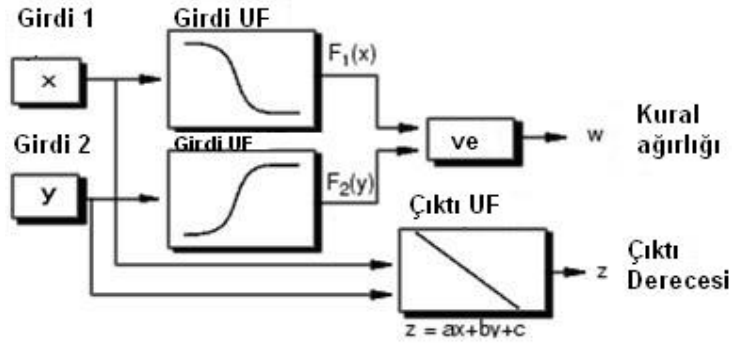
Takagi – Sugeno bulanık mantık ya da Sugeno bulanık mantık ilk kez 1985 yılında kullanılmaya başlanmıştır. Mamdani bulanık mantık yönteminin bir uyarlamasıdır. Girdi değişkenlerinin bulanıklaştırılması ve bulanık mantık işlemleri Mamdani bulanık modelleme ile tamamen aynıdır. İki yöntem arasındaki fark çıktı üyelik fonksiyonlarındadır. Sugeno tipi bulanık modellemede çıktı üyelik fonksiyonları sadece lineer ya da sabittir. Çıktı üyelik fonksiyonları sabit olduğu zaman, sıfırıncı derece, 1. derece doğru denklemi şeklinde olduğu zaman ise birinci derece Sugeno bulanık model olarak adlandırılırlar (URL- 4, 2006). Böylece Sugeno tipi bulanık model, Mamdani tipi bulanık modelden daha karmaşık ve gösterim açısından daha elverişlidir. Bu nedenle Sugeno tipi bulanık model uyarlanabilir tekniklerle birlikte kullanılabilir. Bir birinci (sıfırıncı) derece Sugeno bulanık model aşağıdaki gibi tanımlanabilir.

Eğer $x = A$ ve $y = B$, İse $z = f(x,y) = px+qy+r (c)$.

Burada A ve B , x ve y üyelik fonksiyonları için tanımlanmış öncül kısımdaki bulanık kümeler, p , q ve r ise soncul parametre(ler)dir. Böylece her bir kural için bir çıktı değeri elde edilir. Bulanık küme mantıksal işlemleri (ve, veya) basit toplama ve çarpmadır.

Sistemin sonuç çıktısı, tüm kural çıktılarının ortalamasıyla ağırlıklandırılır ve şu şekilde hesaplanır;

$$sonuç = \frac{\sum_{i=1}^N w_i z_i}{\sum_{i=1}^N w_i} \quad (28)$$



Şekil 1.20. Sugeno tipi bulanık model gösterimi

Sugeno tipi bulanık modelin avantajları aşağıda sıralanmıştır (URL- 3, URL- 4, 2006);

- Hesaplama için çok uygundur.
 - Lineer olmayan sistemlerin kontrol edilmesi için lineer teknikler kullanılabilir.
 - Optimizasyon ve uyarlanabilir (adaptive) tekniklerle birlikte iyi çalışır ve çıktı parametrelerini optimize ederek sonuçları iyileştirir.
 - Çıktı uzayında sürekliliği garantiler.
 - Matematiksel analiz için uygundur.
- Sugeno tipi bulanık modelin dezavantajları ise (URL- 3, 2006);
- Yüksek derecedeki Sugeno bulanık modelleme kullanıldığında oldukça kompleks bir yapıya sahip olur.
 - Girdi ve alt küme sayılarının artması verilerin eğitilmesini zorlaştırır, sonuçların elde edilmesi için belirlenmesi gereken soncul parametrelerin sayısı artar.
 - İnsan sezgilerine çok uygun değildir.

1.6.3. Matlab Bulanık Mantık Modülü

Bulanık Mantık Modülü, Matlab' ın nümerik hesaplama ortamı üzerine kurulu fonksiyonların bütünüdür ve MATLAB iskeletinde FIS (Bulanık Çıkarım Sistemi) düzenlemeyi ve oluşturmayı sağlar. Modül, grafiksel kullanıcı ara yüzü araçlarına bağlıdır.

Modül, 3 araçtan oluşmaktadır. Bunlar,

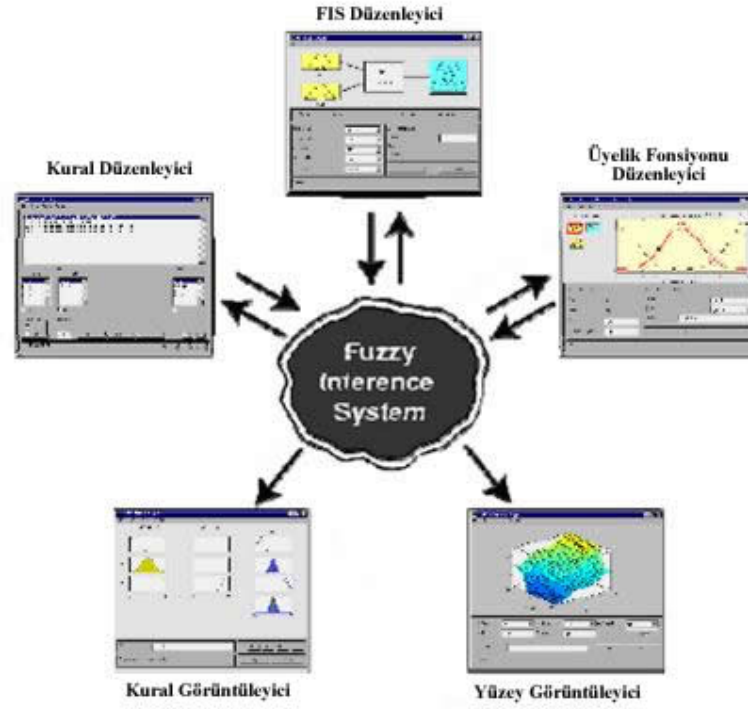
- komut satırı fonksiyonları,
- grafiksel etkileşim araçları,
- bunlara bağlı bloklar ve örnekler

Bulanık Mantık Modülünü komut satırıyla kullanmak mümkün olmasına rağmen, genelde grafiksel olarak sistem kurmak daha kolaydır. Bulanık Mantık Modülünde, bulanık çıkarım sistemi oluşturma, düzenleme ve inceleme için başlıca beş grafiksel kullanıcı ara yüzü vardır. Bunlar;

1. Bulanık Çıkarım Sistemi Düzenleyicisi,
2. Üyelik Fonksiyonu Düzenleyicisi,
3. Kural Düzenleyicisi,
4. Kural Görüntüleyicisi
5. Yüzey görüntüleyici

Bu grafiksel kullanıcı ara yüzleri birbirlerine dinamik olarak bağlıdır, FIS içerisinde birisinde yapılan değişiklikler diğer grafiksel kullanıcı ara yüzlerini de etkilemektedir.

Bu başlıca beş grafiksel kullanıcı ara yüzüne ek olarak modül, Sugeno tipi Adaptif Ağ Yapısına Dayalı Bulanık Çıkarım Sistemlerinin analizi için kullanılan grafiksel Anfis Gui Düzenleyicisini de içerir (Mathworks Inc., 1998).



Şekil 1.21. Bulanık Mantık Modülü Grafikselle Kullanıcı Ara Yüzü

Bulanık Çıkarım Sistem Düzenleyicisi: sistem için gerekli olan üst seviyede işleri yönetir. Kaç tane girdi ve çıktı değişkeni var? İsimleri neler? Bulanık Mantık Modülü girdi sayısını kısıtlamaz. Eğer girdi sayısı çok büyükse, ya da üyelik fonksiyonlarının sayısı çok büyükse Bulanık Çıkarım Sisteminin analizi zorlaşabilir.

Üyelik Fonksiyon Düzenleyicisi: her değişkenle ilgili üyelik fonksiyonlarını tanımlamak için kullanılır.

Kural Düzenleyicisi: sistem davranışını tanımlayan kuralların listesini düzenlemek için kullanılır.

Kural Görüntüleyicisi ve Yüzey Görüntüleyicisi: Hangi kuralların aktif olduğunu ya da özel üyelik fonksiyon şekillerinin sonuçları nasıl etkilediğini gösterir.

Başlıca beş grafiksel kullanıcı ara yüzü birbirini tümüyle etkilemekte, bilgi değişimini sağlamakta ve aynı zamanda açılabilir.

1.7. Sınıflandırmada Doğruluk Analizi

Uzaktan algılama da doğruluk, sınıflandırılmış görüntüdeki piksele tahsis edilen etiket ile, o pikselin gerçek sınıfı arasındaki uygunluğun araştırılmasıdır. Gerçek sınıf, hava fotoğraflarından, mevcut harita ve planlardan ya da GPS ölçmelerinden elde edilebilir. Bu amaçla, sınıflandırma sırasında veya sınıflandırılmış veri üzerinden pikseller seçilerek bu piksellerin referans verilerle uyumu incelenir (Göksel, 1996).

Sınıflandırma hatası, yer doğruluklu ölçmelere dayanarak bilinen bir kategoriye ait olan bir pikselin sınıflandırma sonucunda başka bir gruba atanmasıdır. Sınıflandırma hatası, elektromagnetik yansıma değerlerinin benzemesinden, algılayıcı çözünürlüğünden, radyometrik ve geometrik düzeltmelerden ve sınıflandırma algoritmalarından kaynaklanır.

Piksel yüzeyindeki yeterli doğruluk derecesini sağlamanın bir yolu, görüntü içerisindeki her pikselde arazi örtüsü sınıflandırmasının bir referans kaynakla karşılaştırmaktır. Fakat proje alanının tümü için referans arazi örtüsü bilgilerinin toplanması ekonomik değildir ve uzaktan algılamaya dayanan sınıflandırma yapmanın amacını tümüyle yok eder (Ayhan vd., 2003).

Sınıflandırma da doğruluk analizi, sınıflandırmadan elde edilen sonuçların referans verilerinden çıkarılan test alanlarındaki arazi örtüsünün ‘bilinen’ kimliği ile karşılaştırılmasını içerir. Test alanları, analist tarafından ya da rasgele seçilebilir.

Test alanları analist tarafından seçilirse, mevcut olan yer gerçeği bilgileri temel alınabilir. Fakat kontrollü sınıflandırma yapılmışsa, örnekleme bölgelerinin seçiminde kullanılmış pikselleri test alanı için seçmek kullanıcıya cazip gelir. Bu da testte sapmalara sebep olur, çünkü örnekleme pikselleri sınıflandırmanın temelidir. Doğru bir test yapabilmek için, örnekleme sırasında seçilen pikselleri seçmemek gerekir.

Test alanları rasgele seçilirse, sapma olasılığı elemine edilir. Fakat rasgele seçilmiş olan piksellere, arazi üzerinde ulaşmak zor olabilir. Bu tarz durumlarda arazi örtü haritalarının referans veri olarak kullanılması daha uygundur (Erdas Field Guide, 2002).

Seçilen piksellerle referans verilerinin karşılaştırılması sonucu, sınıflandırılmış piksellerin ait olduğu sınıflara atanma doğrulukları, sınıflandırma hata matrisinden elde edilebilir. Ayrıca hata matrisleri, kapa katsayısı ile istatistik olarak analiz edilebilir.

Doğruluk derecesini tanımlamak için en yaygın yol hata matrisi oluşturmaktır. Hata matrisi; arazide tanımlanan veya hava fotoğraflarından yorumlanan gerçek arazi örtüsüne göre belirli bir arazi örtüsü tipi olarak atanan piksellerin sayısını satırlar ve sütunlar halinde

düzenlemiş sayıların karesel bir düzenidir. Referans verileri matris sütununda, sınıflandırma verileri matris satırında yer alır. Hata matrisi, bilinen referans veriler ile sınıflandırmada bunlara karşılık gelen veriler arasındaki ilişkiyi kıyaslar (Jehnsen, 1996).

Hata matrisinden, sınıflandırmanın doğruluğuna ait birçok ölçüt türetilir. Bunlardan en yaygın olanı, doğru ayrılmış kategorilerin yüzdesinin hesaplanmasıdır. Sınıfların bireysel olarak doğrulukların, bir sınıfa doğru olarak atanan piksellerin toplamının, o sınıfa ait olan tüm piksellerin toplamına oranı hata matrisinden türetilerek bulunabilir. Doğruluk iki yaklaşımla hesaplanabilir; bunlar, üretici doğruluğu ve kullanıcı doğruluğudur. Doğruluk hesaplanırken, matrisin satırları dikkate alınıyorsa, kullanıcı doğruluğu söz konusudur. Eğer, doğruluk hesaplanırken hata matrisinin sütunları kullanılıyorsa, üretici doğruluğundan bahsedilir (Foody, 2002).

Hata matrisi,

	<i>A</i>	<i>B</i>	<i>C</i>	<i>D</i>	<i>Toplam</i>	
<i>A</i>	n_{AA}	n_{AB}	n_{AC}	n_{AD}	n_{A+}	
<i>B</i>	n_{BA}	n_{BB}	n_{BC}	n_{BD}	n_{B+}	
<i>C</i>	n_{CA}	n_{CB}	n_{CC}	n_{CD}	n_{C+}	
<i>D</i>	n_{DA}	n_{DB}	n_{DC}	n_{DD}	n_{D+}	
<i>Toplam</i>	n_{+A}	n_{+B}	n_{+C}	n_{+D}	n	(29)

olmak üzere, üretici ve kullanıcı doğruluğu;

$$\text{Doğruluk yüzdesi : } \frac{\sum_{k=1}^q n_{kk}}{n} * 100 \quad (30)$$

$$\text{Kullanıcı doğruluğu: } \frac{n_{ii}}{n_{i+}} \quad (31)$$

$$\text{Üretici doğruluğu: } \frac{n_{ii}}{n_{+i}} \quad (32)$$

Sınıflandırılmış veriyle referans verisi arasındaki genel doğruluk ifadesi;

$$GD = \frac{\sum_{i=1}^k n_{ii}}{n} \quad (33)$$

eşitliklerinden hesaplanabilir.

Hata matrisi, doğruluğun temsili için etkili bir yoldur çünkü her kategorinin doğruluğu açıkça belirtilir. Atama (commision) ve atlama (omision) hataları matriste gösterilir. Toplam piksel sayısının hata matrisinin ara köşegeni üzerindeki toplam piksel sayısına bölümü sınıflandırma doğruluğudur.

Bazı durumlarda piksel şans sonucu doğru sınıfa atanmış olabilir, bu problemin irdelenmesi için kappa katsayısı kullanarak doğruluk irdelemesi yapmak daha uygundur. Kappa katsayısı, hata matrisinin satır ve sütun toplamları ve köşegenin üzerindeki elemanlar kullanılarak hesaplanır. Kappa katsayısı 0 ile 1 arasında değer alır (Foody, 2002).

Kappa doğruluk değeri şu formüle göre hesaplanır;

$$K_{hat} = \frac{N \cdot \sum_{i=1}^R X_{ii} - \sum_{i=1}^r (X_{i+} * X_{+i})}{N^2 - \sum_{i=1}^r (X_{i+} * X_{+i})} \quad (34)$$

Burada,

N : toplam piksel sayısı (satırdaki ve sütundaki),

r : satır sayısı,

X_{i+} : i satırındaki piksel toplamı,

X_{+i} : i sütunundaki piksel toplamını göstermektedir.


Hata matrisinden ve kappa istatistiğinden elde edilen sonuçlar farklıdır. Çünkü ikisinde farklı bilgiler kullanılır. Hata matrisinde sadece köşegen elemanları kullanılırken, kappa katsayısı için satır ve sütunların ağırlıklı toplamı kullanılır (Jehnsen, 1996).

2. YAPILAN ÇALIŞMALAR

2.1. Çalışma Alanı

Bu tez çalışmasında, Trabzon ilinin, Sanayi, Değirmendere, Kalkınma ve Üniversite mahallelerini içeren yaklaşık 3,6 km x 3,6 km genişliğindeki bir alan, çalışma alanı olarak seçilmiştir.

Bu alana ait çok spektrumlu uydu görüntü verisi Ikonos II algılayıcısından 18 Aralık 2003 tarihinde elde edilmiştir (Şekil 2.1). Görüntü verisi toplam 4 kanaldan ve 900 x 900 pikselden oluşmaktadır.



Şekil 2.1. Çalışma Alanı (Ikonos II, rgb: 3/2/1 doğal renkli uydu görüntüsü)

2.2. Kullanılan Donanım ve Yazılım Özellikleri

Bu tez çalışması kapsamında gerçekleştirilen Yapay Sinir Ağları, Bulanık Mantık ve klasik istatistik Maksimum Olabilirlik karar kuralı tekniklerinin uzaktan algılama uydu

görüntülerinin sınıflandırma problemine getirdikleri yaklaşımların amacını gerçekleştirmek için Karadeniz Teknik Üniversitesi Fotogrametri ve Uzaktan Algılama laboratuvarındaki 3 adet Pentium IV işlemcili bilgisayar grubu kullanılmıştır. Bu performans karşılaştırmalarının maksimum düzeyde genellenebilir olmasını sağlamak için kullanılan Bulanık Mantık algoritması için çok sayıda test yapılmıştır.

Klasik Maksimum Olabilirlik sınıflandırma yöntemi için Erdas Imagine 8.7 ve PCI Geomatica 9.0 yazılımı kullanılmıştır. Bulanık Mantığa dayalı görüntü sınıflandırma uygulaması Matlab programı ortamında programlanmıştır. Yapay Sinir Ağlarına dayalı görüntü sınıflandırma uygulaması, Stuttgart Üniversitesi tarafından geliştirilen Stuttgart Neural Network Simulator (SNNS) programı ve Gebze Yüksek Teknoloji Üniversite' sinde Doç. Dr. Taşkın Kavzoğlu' nun Turbo C' de yazmış olduğu MAPAT programı aracılığı ile gerçekleştirilmiştir.

2.3. Kullanılan Veri Modeli

Bu tez çalışması kapsamında kullanılmakta olan Ikonos II' ye ait 4 kanallı, 4m çözünürlüklü çok spektrumlu uydu görüntü verisi, Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi Jeodezi ve Fotogrametri Mühendisliği Bölümü Uzaktan Algılama Anabilim Dalı' ndan temin edilmiştir. Görüntü verisi ve algılayıcı sistemlerle ilgili ayrıntılar tezin ilgili bölümünde verilmiştir.

Tüm yöntemlerde veri, sınıflandırıcıya tek tek piksel bazında verilmiş ve sonuçta 7 sınıftan birisine girmeye zorlanmıştır. Maksimum Olabilirlik yönteminde piksel paterni, en yakın olasılığa sahip olduğu (en yüksek Gauss olasılık yoğunluk değerini aldığı) sınıfa atanırken YSA ve Bulanık Mantık yapısında Kazanan Hepsini Alır yöntemine uygun olarak en yüksek değer alınmış çıkış katmanı temsil ettiği sınıfa atanmıştır.

2.4. Bilgi Sınıfları ve Eğitim Alanlarının Belirlenmesi

Eğitim verisi olarak adlandırılan veri setleri, tüm görüntüde sınıflandırma işlemine ait istatistikleri kontrol etmek ve sınıflandırma işlemini gerçekleştirmek amacıyla kullanılır. Bir algoritmadaki eğitim verileri, bir uzaktan algılamadaki bilgi sınıflarının eşik değerlerini

ifade eder. Bilgi sınıfları ve arazi örtüsü sınıfları tematik haritadaki katmanlardır (Szymanski, 1998).

Eğitim alanlarına ait veriler, mümkün oldukça uydu görüntüsünün kaydedildiği tarihe yakın bir zaman diliminde araziden toplanmalıdır. Doğru bir sınıflandırmanın yapılabilmesi, eğitim alanlarının arazide homojen bir şekilde belirlenmesi ve yeterli büyüklükte tanımlanması ile mümkündür (Lillesand ve Kiefer, 2000). Eğitim alanları doğrudan arazide belirlendiği gibi görüntü üzerinde çok belirgin alanların çıplak gözle yorumlanmasıyla veya mevcut haritalar aracılığı ile de belirlenebilir.

Tablo 2.1. Sınıf Özellikleri

Sınıf Adı	Sınıf Kodu	Açıklama
Su	1	Deniz ve dereeler
Yeşil 1	2	Bitki örtüsü yoğunluğunun az olduğu çayır tipi alanlar
Yeşil 2	3	Bitki örtüsünün yoğun olduğu orman bölgeleri
Parlak	4	Deformasyona uğramış parlak renkli alanlar
Toprak	5	Tarla tipi çıplak toprak
Yol	6	Ana ve ara yollar
Yerleşim	7	Düzenli ve düzensiz yerleşim alanları

Bu çalışma kapsamında yapılan eğitim alanı tespitinde, uydu görüntü verisinin yüksek çözünürlüklü olması sebebiyle tüm sınıflara ait eğitim alanlarının seçimi uydu görüntüsü üzerinden çıplak gözle yapılmıştır. Hedef sınıfları en iyi derecede temsil edecek ve olabildiğince homojen yapıda seçilen eğitim veri kümesi 7 sınıftan ve toplam 15168 paternden oluşmaktadır. Tablo 2.1’ de seçilen sınıfların özellikleri, Tablo 2.2’ de arazi sınıflarının toplam poligon ve patern sayıları, Tablo 2.3’ te arazi sınıflarının sınıf istatistikleri verilmektedir.

Tablo 2.2. Eğitim alanlarının poligon ve piksel sayıları

Arazi Sınıfı	Eğitim Alanı Poligon Sayısı	Patern Sayısı
Su	8	5149
Yeşil 1	3	1721
Yeşil 2	2	2004
Parlak	4	1666
Toprak	11	2069
Yol	10	1452
Yerleşim	19	1107

Tablo 2.3. Arazi sınıflarının bantlara göre ortalama yansımaya değerleri ve standart sapmaları

Sınıf/Bant	Ortalama				Standart Sapma			
	Bant 1	Bant 2	Bant 3	Bant 4	Bant 1	Bant 2	Bant 3	Bant 4
Su	36.7	49.0	35.4	21.3	14.4	13.3	8.0	21.3
Yeşil 1	22.8	25.6	14.3	86.3	1.6	1.3	0.7	11.3
Yeşil 2	19.7	19.9	13.4	47.2	2.0	1.9	1.0	7.3
Parlak	201.9	195.5	142.3	196.4	53.6	54.1	51.5	60.0
Toprak	53.7	46.9	27.2	61.2	9.6	8.9	5.8	7.9
Yol	48.0	49.4	35.9	47.1	6.9	6.4	4.3	6.8
Yerleşim	74.7	51.9	31.1	77.7	20.6	7.3	4.3	16.6

Tespit edilen eğitim alanlarının irdelemesi sonucu bazı sınıflarda parlaklığın etkili olduğu görülmüştür. Bu nedenle parlaklıklardan etkilenen sınıflar parlak alanlar olarak ayrılarak yeni bir arazi sınıfı altında toplanmıştır.


Erdas Imagine yazılımı ortamında uydu görüntü verisi üzerinden eğitim alanları Şekil 2.2' deki gibi çevrilerek vektör veri formatında kaydedilmiştir. Kontrollü sınıflandırma, yapay sinir ağları kullanılarak yapılan sınıflandırma ve bulanık mantığa dayalı sınıflandırma uygulamalarının hepsinde aynı eğitim alanları kullanılmıştır.



Şekil 2.2. Eğitim alanlarının seçilmesi

Seçilen bu örnek alanların dağılım ve birbirinden ayrılabilirlikleri hem grafik hem de sayısal olarak analiz edilmiştir. Grafik analiz için, iki boyutlu veri özellik uzayında görüntü saçılım grafikleri çizdirilmiştir (Şekil 2.3). Değişik özellik uzaylarında oluşturulan bu grafiklerle hem görüntü verisinin dağılımı hem de seçilen eğitim alanlarının bu dağılıma ve birbirlerine göre sınıf temsil güvenilirlikleri görsel olarak analiz edilmektedir. Bu amaçla görüntü verisi sahip olduğu 4 kanalın bütün ikili kombinasyonlarında PCI Geomatica programında grafik olarak hazırlanmıştır. Bu grafiklerin analizinde, iki boyutlu tüm özellik uzaylarında özellikle 2. ve 3. sınıfların arasındaki örtüşme dikkat çekicidir. 7. sınıftaki ayırt edilebilirlik derecesi düşük seviyede olduğu için, bu sınıfın sınıflandırma performansının zayıf çıkması beklenmektedir. Grafik irdelemede zayıf ayırt edilebilirlik derecesine sahip olan bu sınıfın

durumu, dönüştürülmüş diverjans analiziyle sayısal olarak daha objektif bir şekilde analiz edilebilir (Jehnsen, 1996).



Şekil 2.3. İki boyutlu özellik uzaylarında eğitim örneklerinin dağılımları

Oluşturulan sınıf alıştırma örneklerinin 4 boyutlu özellik uzayındaki ayrılabilirlik analizi, PCI Geomatica yazılımında kantitatif olarak da incelenmiştir. Bu amaçla sınıf örnek alanlarının 4 kanal için Bhattacharyya uzaklığı ve dönüştürülmüş diverjans

değerleri hesaplanmıştır. Literatürde, Bhattacharrya uzaklığı değerlerinin derecelendirilmesine göre 2.0-1.90 arası çok iyi seviyede bir ayırım derecesini, 1.90-1.70 arası iyi ve 1.70 den küçük ise zayıf bir ayırım derecesini göstermektedir (Geomatica Prime Help, 2003). Bu değerlerin hesaplanması için Pci Geomatica programı, verilen derecelendirmeye uygun olarak dönüştürülmüş diverjans değerlerini kullanarak sınıfların hangi ayrılabilirlik seviyesine girdiğini belirtmektedir. Bu derecelendirmeye göre; zayıf ayrılabilirlik derecesine toprak ve yerleşim alanları sınıfları girmektedir. Grafik analizde belirli özellik uzaylarında birbiri üzerine bindiren sınıflar için dönüştürülmüş diverjans analizinde tüm sınıflar en düşük ayrılabilirlik derecesi göstermemektedir. Bhattacharrya uzaklığı ve dönüştürülmüş diverjans değerleri, Tablo 2.4 ve Tablo 2.5’ te verilmiştir.

Tablo 2.4. Bhattacharrya uzaklığı değerleri

Sınıf	su	bitki	gurbitki	parlak	toprak	yol
bitki	2.0000	0.0000	1.9412	1.9999	1.9979	1.9999
gurbitki	2.0000	1.9412	0.0000	1.9994	1.9794	1.9997
parlak	1.9460	1.9999	1.9994	0.0000	1.9047	1.9008
toprak	1.9999	1.9979	1.9794	1.9047	0.0000	1.9189
yol	1.9938	1.9999	1.9997	1.9008	1.9189	0.0000
yerlesim	1.9995	1.9999	1.9996	1.9459	1.3886	1.8853

Tablo 2.5. Dönüştürülmüş diverjans değerleri

Sınıf	su	bitki	gurbitki	parlak	toprak	yol
bitki	2.0000	0.0000	1.9717	2.0000	2.0000	2.0000
gurbitki	2.0000	1.9717	0.0000	2.0000	2.0000	2.0000
parlak	2.0000	2.0000	2.0000	0.0000	2.0000	2.0000
toprak	2.0000	2.0000	2.0000	2.0000	0.0000	1.9491
yol	1.9998	2.0000	2.0000	2.0000	1.9491	0.0000
yerlesim	2.0000	2.0000	2.0000	2.0000	1.9981	2.0000

2.5. Kontrollü Sınıflandırma Uygulaması

Bir görüntüdeki beklenen arazi farklılıklarını grup/sınıflar halinde bilinen alanlar yardımıyla belirlenmesi işlemidir. Bu işlem; sırasıyla alana ait ön bilgilerin toplanması, eğitim alanlarının belirlenmesi, sınıflandırmanın yapılması ve sınıflandırmanın başarısının denetlenmesi aşamalarından oluşmaktadır (Erdas Field Guide, 2002)

Bu çalışmada kontrollü sınıflandırma metodu olarak Maksimum Olabilirlik (Maximum Likelihood) algoritması kullanılmıştır. Maksimum Olabilirlik karar kuralı, her bir sınıfın Gauss olasılık yoğunluk fonksiyonunun 2. derece istatistiklerine dayanan parametrik bir sınıflandırma tekniğidir. Eğer sınıf dağılımları normal dağılıma uyuyorsa Maksimum Olabilirlik karar kuralı en optimal yöntemdir.

İkonos' tan elde edilen Trabzon' un Merkez bölgesine ait olan uzaktan algılanmış görüntüsü 4 kanallı olarak sınıflandırılmıştır. İkonos uydu görüntüsünün kontrollü sınıflandırmaya tabi tutulması ile elde edilen sonuçlar, alana ilişkin pankromatik uydu görüntüsü kullanılarak kontrol edilmiştir. Sınıflandırmanın başarısı, Erdas Imagine 8.6 programında 210 deneme alanından oluşan piksel bazında test verisi kullanılarak kontrol edilmiştir. Uygulanan kontrollü sınıflandırma sonucunda, sınıflandırmanın toplam doğruluk yüzdesi, kullanıcı ve üretici doğrulukları ile bu doğrulukların istatistiki olarak değerlendirilmesini sağlayan Kappa değerleri hesaplanmıştır. Yapılan kontrollü sınıflandırmanın başarısını özetleyecek olursak; toplam sınıflandırma doğruluğu %67,62, Kappa istatistik değeri 0,6020 olarak başarısız bulunmuştur. Kontrol esnasında her bir arazi sınıfına düşen tüm kontrol noktaları 1m çözünürlüklü pankromatik İkonos uydu görüntüsünden kontrol edilmiş ve eğer farklı bir sınıfta ise o sınıf değeri girilmesi suretiyle görüntülerin başarısı ölçülmüştür.

Sınıflandırma sonucunun hata matrisi, genel sınıflandırma doğruluğu, kappa istatistik değerleri ve sınıfların kullanıcı ve üretici doğruluk yüzdeleri Tablo 2.6' da yer almaktadır. Burada Su olarak nitelendirilen sınıfın üretici doğruluğu %96,43, kullanıcı doğruluğu %100 ve kappa istatistiği 1 olup yüksek başarı oranı ile ayrılabilir. Yerleşim alanları %66,67 kullanıcı doğruluğu ile düşük değere sahiptir. Kappa istatistik değeri 0,6392 olduğundan ilgili sınıfın ayrılmasında istenilen başarı sağlanamamıştır. Çünkü kappa istatistiği değeri, 0-1 aralığında değişmekte ve 0,8 oranından büyük değerler başarılı sayılmaktadır. Trabzon ilindeki yerleşim alanlarındaki yapılaşmanın dağınık olmasından dolayı iskan alanlarının ayırımında başarı sağlanamamıştır. Sınıf dağılımlarının normal

dağılıma uymaması ve bunun sonucunda dağılımların birbirine girmesinden dolayı diğer sınıfların ayırımında da başarı sağlanamamıştır.

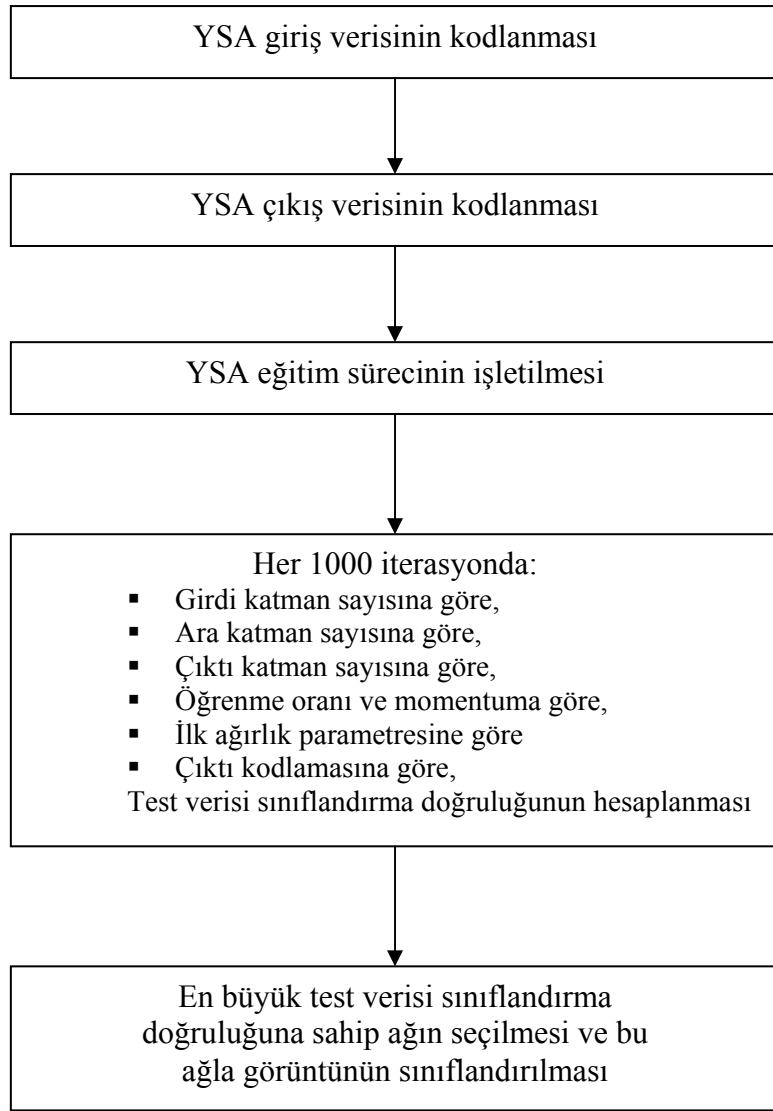
Tablo 2.6. Uydu görüntüsünün Maksimum Olabilirlik sınıflandırma sonuçlarının hata matrisi

Sınıf Kodu	1	2	3	4	5	6	7	Sınıflandırılmış nokta sayısı	Üretici Doğruluğu
1	27	0	0	0	0	0	0	27	96.43
2	0	55	3	0	3	1	0	62	77.46
3	0	9	15	0	3	2	0	29	65.22
4	0	1	0	8	5	5	7	26	80.00
5	0	5	4	1	23	6	2	41	63.89
6	1	0	1	1	2	12	5	22	46.15
7	0	1	0	0	0	0	2	3	12.50
Referans Nokta Sayısı	28	71	23	10	36	26	16	210	
Kullanıcı Doğruluğu	100	88.71	51.72	30.77	56.10	54.55	66.67		
Kappa İstatistik Değerleri	1.0	0.8294	0.4579	0.2731	0.4701	0.4812	0.6392	0.6020	

2.6. Yapay Sinir Ağları Uygulaması

Bu tez çalışmasında Yapay Sinir Ağları uygulaması için çok katmanlı algılayıcı ağ yapılarından geri yayılma öğrenme algoritması kullanılmıştır. Yapılan YSA sınıflandırma uygulaması hem kendi içinde hem de literatürde yaygın olarak kullanılan ve genel kabul görmüş kontrollü sınıflandırma yönteminin sonuçlarıyla ve bulanık mantığa dayalı sınıflandırma yöntemi sonuçlarıyla karşılaştırılmıştır.

Görüntü verilerinin YSA ile sınıflandırılmasında izlenen aşamalar Şekil 2.4' te gösterilmektedir. İlk aşamada uydu görüntü verisi üzerinden eğitim ve test alanları seçilmiş, tüm görüntü ve belirlenen eğitim ve test alanlarına ait paternler YSA' da işlenmeye uygun hale getirilmiştir.




Şekil 2.4. YSA ile sınıflandırmada hesap akış şeması

Kullanılan YSA geri yayılım algoritmasında giriş katmanı, kullanılan her bir kanala karşılık bir yapay nöron gelecek şekilde 4 nöron tesis edilmiştir. Çıkış katmanı hedeflenen 7 sınıfın her birine bir nöron gelecek şekilde tesis edilmiştir. YSA hedef değerleri, ilgili sınıfa ait olması beklenen nöron için 1, ait olmayan diğerleri için 0 olarak belirlenmiştir. YSA ara katman sayısı, ilk ağırlık parametresi, öğrenme parametresi ve momentum oranı uzaktan algılanmış görüntülerin sınıflandırma problemine en iyi yakınsamayı getirecek en iyi değerleri deneme yanılma yöntemiyle belirlenmeye çalışılmıştır ve tüm bu ağı tasarımı ve öğrenmesini etkileyen parametreler tek tek bulgular ve irdeleme bölümünde ele alınmış ve optimum ağ yapısı tasarlanmıştır.

2.6.1. Patern Dosyalarının Hazırlanması ve Örneklenmesi

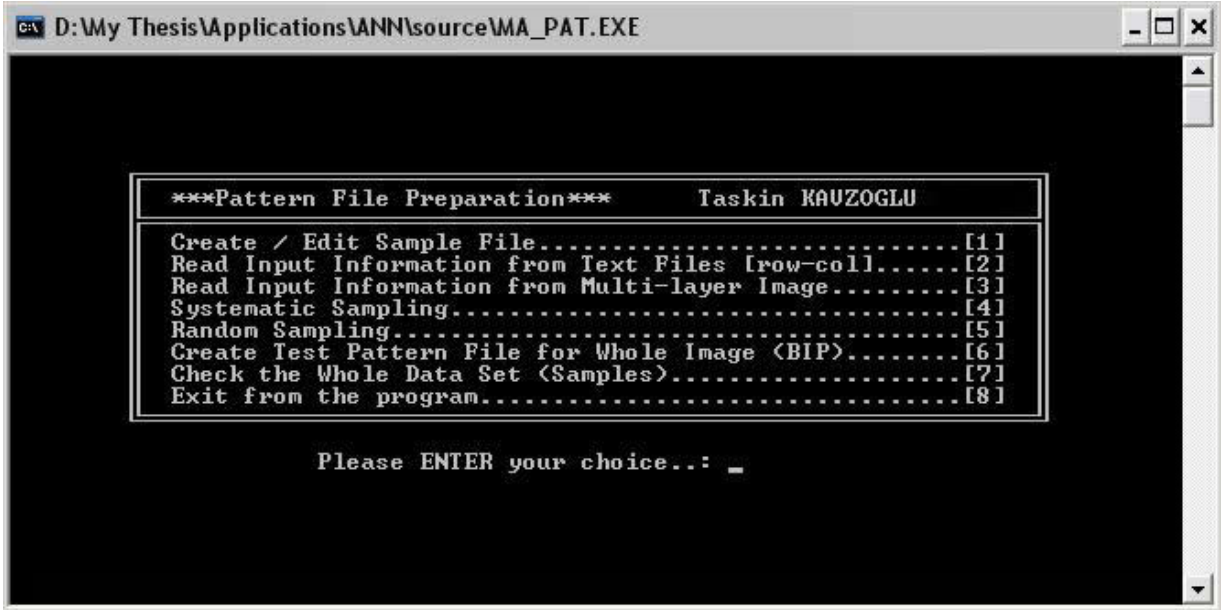
İlk adım YSA sınıflandırması için patern dosyalarının hazırlanmasıdır. Sınıflandırma doğruluğu ve çalışma boyunca gerçekleştirilecek tüm işlemler, görüntü verisinin özelliklerini içeren bu dosyaya bağlıdır. Bu sebeple patern dosyalarının hazırlanması işlemi, çok dikkatli bir şekilde yapılmalıdır.

Vektör veri formatında kaydedilmiş olan eğitim ve test alanları raster veri formatına dönüştürülmüştür. Raster veri formatındaki eğitim ve test alanları 4 bantlı uydu görüntü verisi üzerine eklenerek 5 bantlı uydu görüntü verisi oluşturulur (Şekil 2.5). Bu dosya Erdas Imagine ortamında *bip* (*Band Interlaced by Pixel*) dosya formatına dönüştürülerek YSA uygulaması için hazır hale getirilmiş olur.



Şekil 2.5. Eğitim ve test alanlarını içeren 5 bantlı uydu görüntüsü

Bu işlemlerden sonra MA_PAT programı çalıştırılır ve sekiz seçenekten oluşan menü MS-DOS ortamında açılır (Şekil 2.6).



Şekil 2.6. MA_PAT program menüsü

Bu programla, görüntü üzerinden iki çeşit örnekleme adımı gerçekleştirilebilir. Birincisi, sol üst köşe koordinat değerleriyle birlikte satır ve sütunlarla dikdörtgen tanımlanarak piksellerin seçimidir. Create / Edit Sample File (Patern dosyası oluştur/düzenle) seçilerek tüm görüntüdeki bilgiler ascii metin dosyasında depolanır. Bu dosyaya bir örnek Şekil 2.7' de verilmiştir.


```

5 280 475 6 24
275 152 301 174 580514.007 276552.410 4
441 91 451 100 584497.257 278017.160 7
301 122 316 136 581136.882 277273.535 3
169 205 175 219 577968.882 275281.535 6
327 121 339 136 581760.882 277297.535 1

```

Şekil 2.7. Birinci örnekleme adımına ait metin dosyası

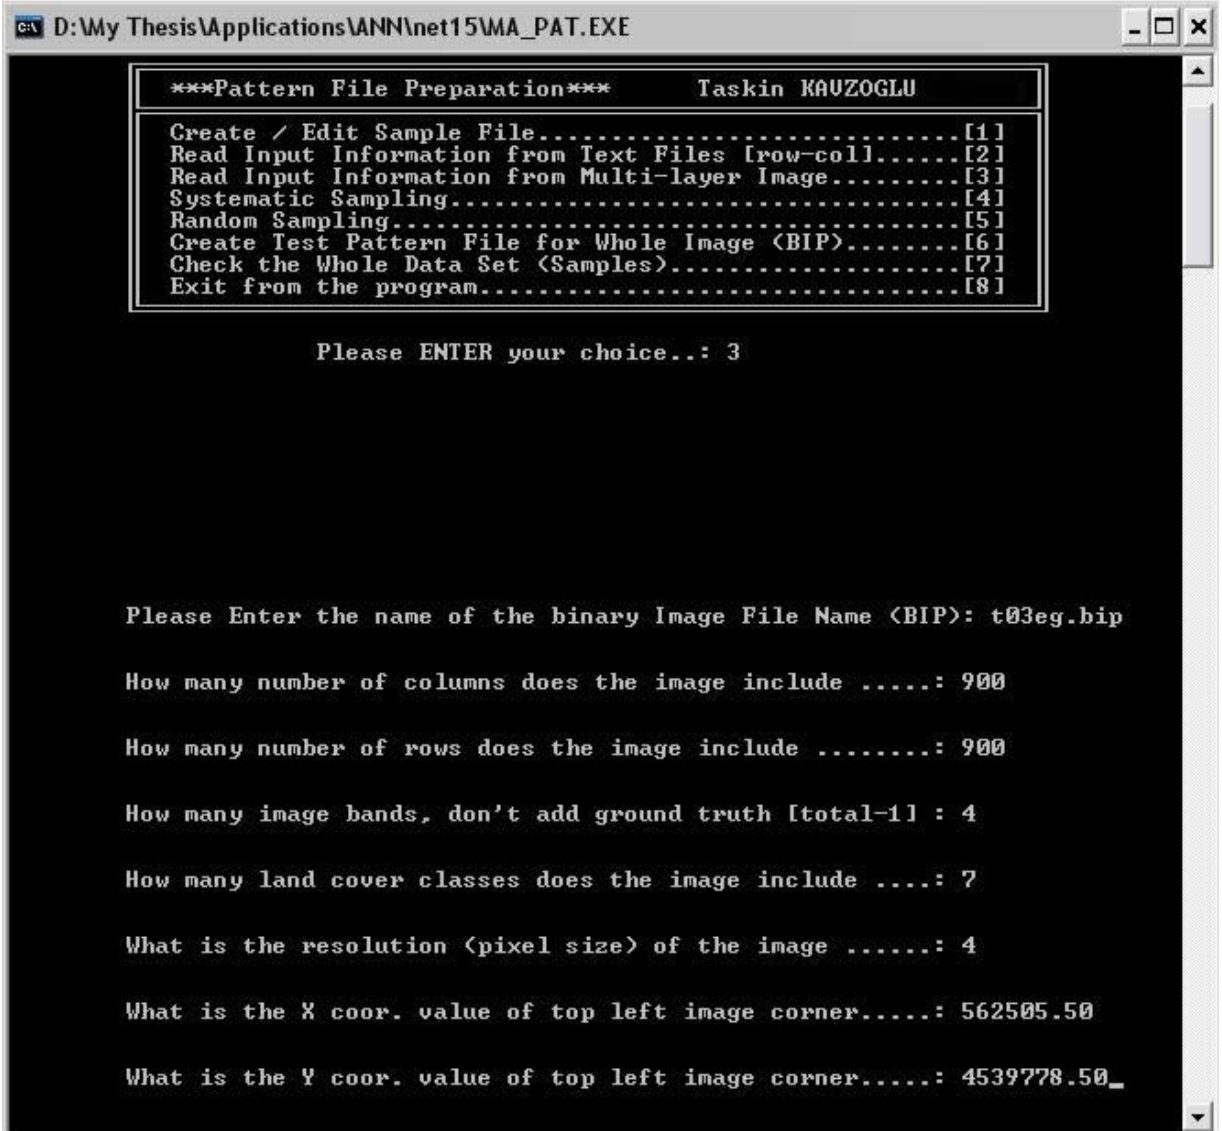
İlk satır, örneklerin sayısını, görüntüdeki satır ve sütunların sayısını, bantların sayısını ve görüntü çözünürlüğünü göstermektedir. İkinci satır, dikdörtgen alandaki satır ve sütunların sayısını ve sınıf derecesini göstermektedir. Dikdörtgen alanın tanımlanmasına ilişkin bir örnek Şekil 2.8’ de verilmiştir.



Şekil 2.8. Dikdörtgen alanın seçimi

X ve Y koordinatları Erdas Imagine yazılımından alınmıştır. MS-DOS menüsünde ikinci seçenek seçilerek dikdörtgendeki satır ve sütunlar kullanılmasıyla görüntüyle ilgili tüm bilgiler programa okutulur. Her pikselin koordinat değerleri hesaplanır ve tüm bilgiler örnekleme işleminde kullanılmak üzere bir dizide saklanır. Görüntünün kullanılabilmesi için görüntü formatının *bsq* (*Band Sequential*) olması gerekmektedir.

İkinci örnekleme seçeneği, bu tez çalışmasında kullanılan adımdır (Şekil 2.9). Bu işlem, görüntüde yer gerçekli verinin kullanılmasıyla mümkündür (Read Input Information from Multi-Layer Image). Bu seçenek için, *bip* formatındaki uydu görüntü verisi programa girilir ve program görüntü verisiyle ilgili bazı bilgiler sorar. Seçilen her pikselin koordinatlarının hesaplanması için girilmesi gereken girdi verileri, görüntüdeki satır ve sütun sayıları, bant sayıları, oluşturulmak istenen sınıf sayısı, görüntü çözünürlüğü ve görüntü köşe koordinatlarıdır. Görüntü okunurken, program rasgele, piksellerin sınıf etiketlerini arar, her bant için piksel değerlerini okur ve bunları bir dizide saklar. Bir sınıf için çok fazla paternin seçiminden sakınmak için program, her sınıfın patern sayısını hesaplar ve her sınıf için eşit sayıda patern seçmeyi dener. Son olarak, her pikselin koordinatı hesaplanır ve bir diziyeye eklenir. İkinci örnekleme adımına ait *ascii* dosyası Şekil 2.10’ da verilmiştir.



Şekil 2.9. MA_PAT programında görüntü verisinin programa okutulması işlemi

Burada her satır, görüntüdeki bantlara ait piksel değerlerini ve sınıf derecesini göstermektedir.

K	Y	M	I	S
17	28	25	98	1
18	27	23	82	2
18	24	21	74	3
17	25	21	69	4
17	26	23	72	5
18	26	24	85	6
17	26	23	83	7

Şekil 2.10. İkinci örnekleme adımına ait metin dosyası

Program, hafızasında tuttuğu veri için sistematik örnekleme ve rasgele örnekleme olmak üzere iki örnekleme seçeneği sunar. Sistematik örneklemede, eğitim örnek dosyasının biçimlendirilmesi için dizideki tüm veri seçilir. Rasgele örnekleme ise, daha karmaşık bir işlemdir ve çalışmada bu işlem kullanılmıştır (Şekil 2.11).

```

D:\My Thesis\TEZ\text\printscreen\MA_PAT.EXE

Class 1 : 1200
Class 2 : 1200
Class 3 : 1200
Class 4 : 1200
Class 5 : 1200
Class 6 : 1200
Class 7 : 1100

Your choice cannot be bigger than one of the above number of patterns
Please Specify Number of Pattern for each Class : 700

Do you want to save the results to pattern files [1<yes>, 2<no>] : 1

Training Pattern File [1]
Testing Pattern File [2]

Enter your choice : 1

Enter output file name...: train.pat

Please specify a TEXT FILE NAME for Accuracy Assessment : train.acc

Please give a letter to represent 1. class : su
Please give a letter to represent 2. class : yesil1
Please give a letter to represent 3. class : yesil2
Please give a letter to represent 4. class : parlak
Please give a letter to represent 5. class : toprak
Please give a letter to represent 6. class : yol
Please give a letter to represent 7. class : yerlesim

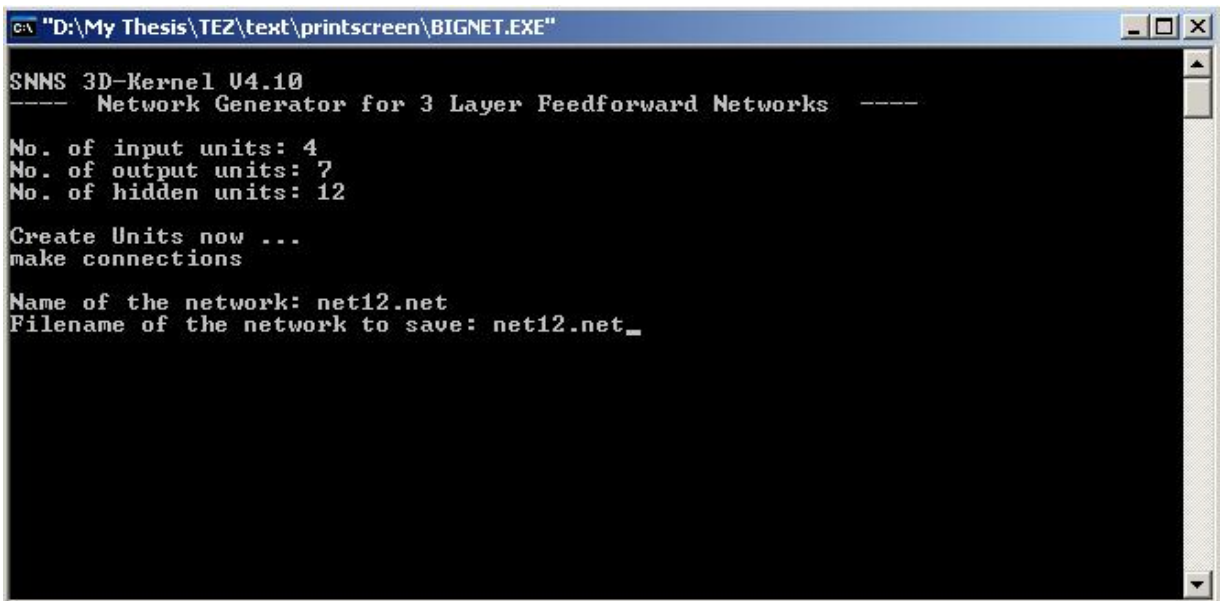
```

Şekil 2.11. Rasgele örnekleme yapılarak patern sayılarının her sınıf için seçilmesi işlemi

Bunun için iki seçenek kullanılır; görüntü verisi için toplam patern sayısı ya da paternlerin sayısı her sınıf için seçilebilir. Çalışmada paternlerin sayısı her sınıf için seçilmiştir. Program her sınıf için patern sayısını listeler ve kullanıcının isteğine bağlı olarak patern sayısını sorar. Bu sayı, bir sınıfa ait en küçük patern sayısına eşit veya daha az olmalıdır. Çalışmada eğitim paternleri için 700 örnek ve test paternleri için 2500 örnek seçilmiştir. Bu işlemden sonra örnekleme tamamlanmış, eğitim ve test patern dosyaları SNNS formatında kaydedilmiştir. Her bant için seçilen piksellere ait bilgi ve sayısal değerler programın 7 numaralı seçeneği ile görüntülenebilir.

2.6.2. Ağ Dosyasının Oluşturulması

Örnekleme adımından sonra, YSA' nın eğitiminde kullanılacak ağ dosyasının oluşturulması işlemine geçilir. Bunun için SNNS' in modülü olan BIGNET programı çalıştırılır. Bu program SNNS yazılımı tarafından sağlanan bir C programıdır. Masaüstü bilgisayarlarda kullanılmak üzere Turbo C'de derlenmiştir. Programa girdi, çıktı ve ara katman sayıları verilerek, rasgele seçilmiş ağırlıklar kümesi ile *net* formatında ağ dosyası oluşturulmuştur. Girdi, çıktı ve ara katman sayıları, literatüre göre ve deneme yanılma yöntemiyle tezin bulgular ve irdeleme bölümünde belirlenmeye çalışılmıştır. Programın ara yüzüne örnek Şekil 2.12' de verilmiştir.



```

C:\ "D:\My Thesis\TEZ\text\printscreen\BIGNET.EXE"
SNNS 3D-Kernel U4.10
---- Network Generator for 3 Layer Feedforward Networks ----
No. of input units: 4
No. of output units: 7
No. of hidden units: 12
Create Units now ...
make connections
Name of the network: net12.net
Filename of the network to save: net12.net_

```

Şekil 2.12. BIGNET programı ara yüzü

2.6.3. Konfigürasyon Dosyalarının Hazırlanması ve Koşturulması

Ağ dosyası oluşturulduktan sonraki adım, sinir ağlarının eğitilmesi için gerekli konfigürasyon dosyasının hazırlanmasıdır. Bunun için SNNS' in bir modülü olan MAKECFG programı çalıştırılmış ve ağın eğitimi için gerekli parametreler girilerek konfigürasyon dosyası otomatik olarak SNNS formatında oluşturulmuştur. Konfigürasyon dosyası, öğrenme parametreleri, sinir ağı dosyası ve eğitim patern dosyası girilerek cfg formatında oluşturulur. Öğrenme parametreleri olan ilk ağırlık parametresi, öğrenme oranı ve momentum literatüre göre ve deneme yanılma yöntemiyle tezin bulgular ve irdeleme bölümünde en iyi şekilde belirlenmeye çalışılmıştır.

Konfigürasyon dosyasının oluşturulmasından sonra, konfigürasyon dosyasının işlenerek ağın eğitilmesi işlemine geçilmiştir. Bunun için SNNS' in konfigürasyon işleme dili olan 'Batchman' kullanılmıştır. Bu program eğitim hataları ve iterasyon sayılarıyla ilgili bilgilerin görüntülenmesine izin verir. Konfigürasyon dosyaları Batchman' de işlenerek ağın eğitilmesi işlemi tamamlanmıştır (Şekil 2.14). Çalışmada kullanılan konfigürasyon dosyası Şekil 2.13' de verilmiştir.

```

loadNet("net11.net")
loadPattern("train.pat")
loadPattern("test.pat")
setPattern("train.pat")
setInitFunc("Randomize_Weights",-0.3,0.3)
initNet()
setLearnFunc("Std_Backpropagation",0.1)
setUpdateFunc("Topological_Order")
setShuffle(TRUE)
while SSE > 0.1 and CYCLES < 15000 do
for i:=1 to 1000 do
if CYCLES mod 1000 == 0 then
print("cycles = ",CYCLES, " SSE = ",SSE," MSE = ",MSE) endif
trainNet()
endifor
saveNet("1net" + CYCLES div 1000 + ".net")
setPattern("test.pat")
saveResult("1res" + CYCLES div 1000 + ".res",1,PAT,TRUE,FALSE,"create")
setPattern("train.pat")
endwhile
print("Cycles trained: ", CYCLES)
print("Training stopped at error(SSE): ", SSE)

```

Şekil 2.13. Çalışmada kullanılan konfigürasyon dosyası

```

C:\ batchman -f uyg2.cfg
D:\My Thesis\TEZ\text\printscreen>batchman -f uyg2.cfg
Net net15.net loaded
Patternset val.pat loaded; 1 patternset(s) in memory
Patternset train.pat loaded; 2 patternset(s) in memory
Init function is now Randomize_Weights
Parameters are: -0.2 0.2
Net initialized
Learning function is now BackpropMomentum
Parameters are: 0.3 0.6
Update function is now Topological_Order
Pattern shuffling enabled
cycles = 20 SSE = 646.074 MSE = 0.131852
Patternset is now val.pat
cycles = 20 SSE = 115.897 MSE = 0.165567
MSE1= 100 MSE2 = 0.165567 DIFF = 99.8344
Network file tnet.net written
Patternset is now train.pat
cycles = 40 SSE = 485.605 MSE = 0.0991031
Patternset is now val.pat
cycles = 40 SSE = 66.8767 MSE = 0.0955381
MSE1= 0.165567 MSE2 = 0.0955381 DIFF = 0.0700291
Network file tnet.net written
Patternset is now train.pat
cycles = 60 SSE = 390.914 MSE = 0.0797784
Patternset is now val.pat
cycles = 60 SSE = 48.8823 MSE = 0.0698319
MSE1= 0.0955381 MSE2 = 0.0698319 DIFF = 0.0257062
Network file tnet.net written
Patternset is now train.pat
cycles = 80 SSE = 326.967 MSE = 0.066728
Patternset is now val.pat
cycles = 80 SSE = 45.8833 MSE = 0.0655475
MSE1= 0.0698319 MSE2 = 0.0655475 DIFF = 0.00428438
Network file tnet.net written
Patternset is now train.pat
cycles = 100 SSE = 298.161 MSE = 0.0608493
Patternset is now val.pat
cycles = 100 SSE = 58.8271 MSE = 0.0840387
MSE1= 0.0655475 MSE2 = 0.0840387 DIFF = -0.0184912
Patternset is now train.pat
cycles = 120 SSE = 276.718 MSE = 0.0564731
Patternset is now val.pat
cycles = 120 SSE = 45.9009 MSE = 0.0655727
MSE1= 0.0655475 MSE2 = 0.0655727 DIFF = -2.5177e-05
Patternset is now train.pat

```

Şekil 2.14. Konfigürasyon dosyalarının SNNS' in Batchman modülünde işletilmesi

2.6.4. Yapay Sinir Ağlarının Test Edilmesi

Yapay Sinir Ağlarının eğitilmesinden sonra test edilmesi işlemi gerçekleştirilir. Bunun için test patern dosyasıyla beraber eğitilmiş sinir ağı dosyası kullanılarak konfigürasyon dosyası oluşturulmuştur. Bu dosya metin editöründe hazırlanmış ve *cfg* formatında kaydedilmiştir. Konfigürasyon dosyası SNNS' in konfigürasyon işleme dili olan Batchman' de işletilmiş ve sonunda *res* formatında test sonuç dosyaları hazırlanmıştır. Çalışmada kullanılan konfigürasyon dosyasına örnek Şekil 2.15' te verilmiştir.

```

loadPattern("test.pat")
loadNet("tnet1.net")
saveResult("test1.res", 1, PAT, TRUE, FALSE, "create")

loadNet("tnet2.net")
saveResult("test2.res", 1, PAT, TRUE, FALSE, "create")

loadNet("tnet3.net")
saveResult("test3.res", 1, PAT, TRUE, FALSE, "create")

```

Şekil 2.15. Test sonuç dosyalarının hazırlanması için kullanılan konfigürasyon dosyası

2.6.5. Doğruluk Analizi

Bir sınıflandırma işleminde doğruluk analizi en önemli adımdır. Bu tez çalışmasında yapay sinir ağlarıyla yapılan sınıflandırmaların tümü olasılık matrisi metoduna dayalı olarak ACASS programında yapılmıştır (Şekil 2.17). Bunun için program iki dosya adı ve eşik değeri sormaktadır. Bu dosyalar, SNNS'in *res* formatında oluşturulan test sonuç ve *acc* formatında oluşturulan arazi sınıflarını tanımlayıcı metin dosyalarıdır. Test sonuç dosyası konfigürasyon dosyasının işletilmesiyle oluşturulmuştur. Sınıflara ait bilgi dosyası Şekil 2.16' da gösterildiği gibi üç çeşit bilgi içermektedir.

Sınıf	Örnek Sayısı	Sınıf
a	382	1
b	373	2
c	373	3
d	365	4
e	370	5
f	367	6
g	270	7

Şekil 2.16. Sınıflara ait bilgi dosyası

Çalışmada kullanılan bilgi dosyasında, a, b, c, d, e, f ve g su, yeşil 1, yeşil 2, parlak, toprak, yol ve yerleşim sınıflarını, 382, 373, 373, 365, 370, 367, 270 değerleri her sınıfa ait toplam piksel sayısını ve 1, 2, 3, 4, 5, 6, ve 7 değerleri sınıf numaralarını göstermektedir.

Program öncelikle su sınıfına ait ilk 382 pikselin üyeliğinin doğruluğunu ve YSA sınıflandırıcısı tarafından doğru bir şekilde sınıflandırılan su piksellerinin sayısını hesaplar. Bu doğruluk her sınıf için ayrı ayrı gerçekleştirilir ve formüle göre doğruluk ölçüleri hesaplanır.

File Name : 1res5.res		Threshold : 0.0						
* CONTINGENCY MATRIX *				Taskin KAUZOGLU				
	a	b	c	d	e	f	g	Total
a	382	0	0	0	0	0	0	382
b	0	372	1	0	0	0	0	373
c	0	3	369	0	1	0	0	373
d	0	0	0	365	0	0	0	365
e	0	2	1	0	357	3	7	370
f	0	0	0	0	1	365	1	367
g	0	0	0	0	10	1	259	270
Total	382	377	371	365	369	369	267	2500
Overall : % 98.760 Kappa : 98.551 Z : 381.097 Unr : 0								
Acc. %	100	99.73	98.93	100	96.49	99.46	95.93	
Con. K	100	99.68	98.74	100	95.88	99.36	95.44	

Thank you Byeee.....

Şekil 2.17. Olasılık matrisiyle yapılan doğruluk analizi

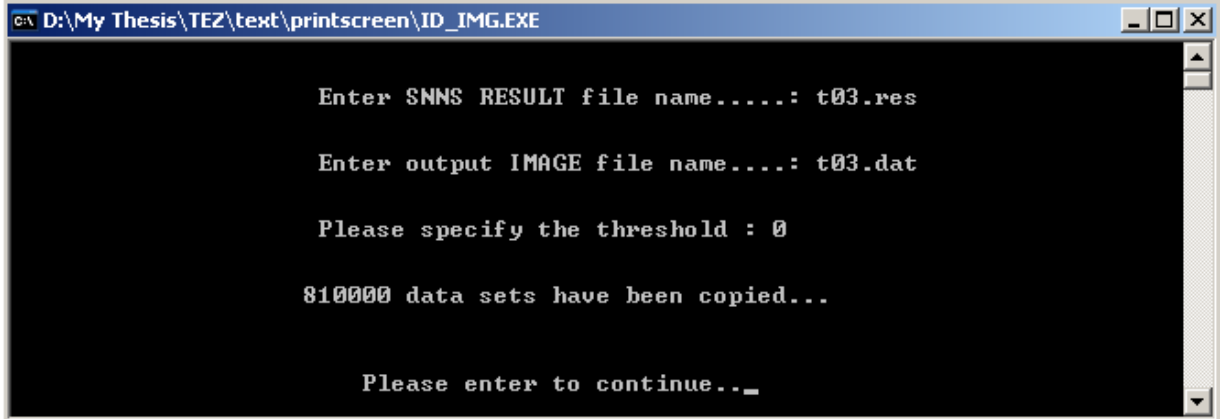
Tezin bulgular ve irdeleme bölümünde incelenen ağ tasarımıyla ilgili parametreler için test sonuç dosyaları hazırlanmış ve doğruluk analizleri yapılmıştır. En iyi doğruluğu veren ağ tasarımı bu sayede belirlenmiş ve uydu görüntüsü optimum ağ tasarımına göre sınıflandırılmıştır. Optimum ağ tasarımı için en iyi değerler Tablo 2.7' de gösterilmiştir. Yapay sinir ağlarının sınıflandırılması sonucunda toplam doğruluk %98,76 ve Kappa istatistik değeri 0,9855 bulunmuştur.

Tablo 2.7. Optimum ađ tasarımına göre sınıflandırma sonucu

Parametreler	Seçim / Sonuç
Girdi katman sayısı	4
Çıktı katman sayısı	7
Ara katman sayısı	14
İlk ağırlık aralığı	[-0.1, 0.1]
Öğrenme oranı ve momentum	0.15 – 0.075
Çıktı kodlaması	[0 1 0]
İterasyon	5000
Toplam Doğruluk	98.76
Kappa İstatistiği	0.9855

2.6.6. Görüntü Dosyalarının Hazırlanması

Oluşturulan sonuç görüntü dosyaları SNNS formatında olduğundan bu dosyaların görüntülenebilmesi için Erdas formatına çevrilmesi gerekmektedir. Bu işlem için SNNS' in modülü olan ID_IMG programı kullanılmıştır . Bu program, SNNS formatındaki işlenen sonuç dosyalarını ve sınıf değerlerini Idrisi yazılımı için uygun formata dönüştürmektedir. Tez çalışması kapsamındaki görüntüler bu program kullanılarak Idrisi formatında kaydedilmiştir, ardından Erdas görüntü formatına dönüştürülmüştür.



```

D:\My Thesis\TEZ\text\printscreen\ID_IMG.EXE

Enter SNNS RESULT file name.....: t03.res

Enter output IMAGE file name....: t03.dat

Please specify the threshold : 0

810000 data sets have been copied...

Please enter to continue.._

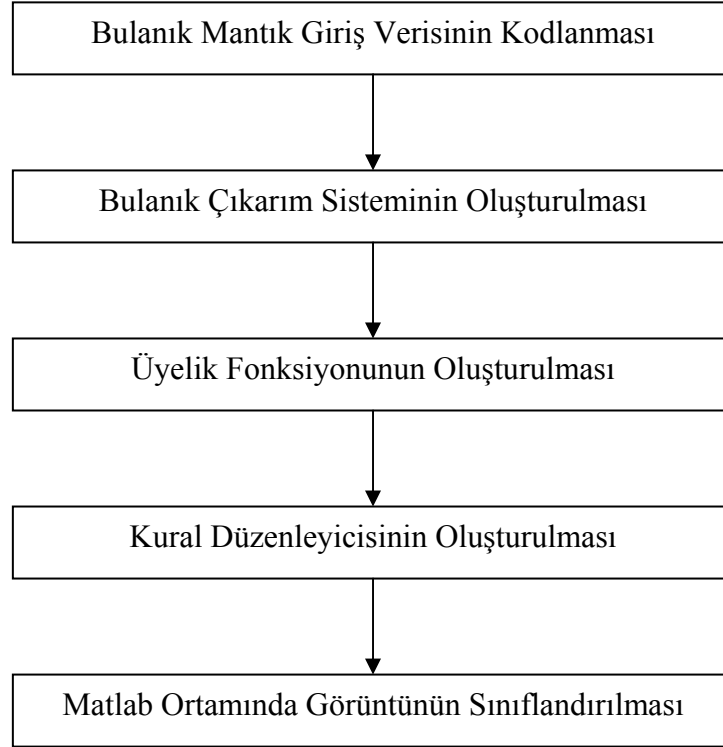
```

Şekil 2.18. ID_IMG programı ara yüzü

2.7. Bulanık Mantığa Dayalı Görüntü Sınıflandırma Uygulaması

Bulanık mantığa dayalı görüntü sınıflandırma uygulaması için 4 bantlı Ikonos uydu görüntü verisi kullanılmıştır. Sınıflandırma için girdi verisi olarak tez çalışması kapsamında tüm sınıflandırma uygulamalarında kullanılan aynı eğitim paternleri kullanılmıştır.

Uygulama için Matlab yazılımının bulanık mantık modülü ve Pci Geomatica yazılımı kullanılmıştır. Pci Geomatica programından alınan üyelik fonksiyon parametreleri kullanılarak bulanık çıkarım sistemi (FIS) oluşturulmuştur. Bulanık Çıkarım Sisteminin yapısının daha iyi anlaşılması için ascii dosyası biçiminde gösterilmiştir (Ek 1).

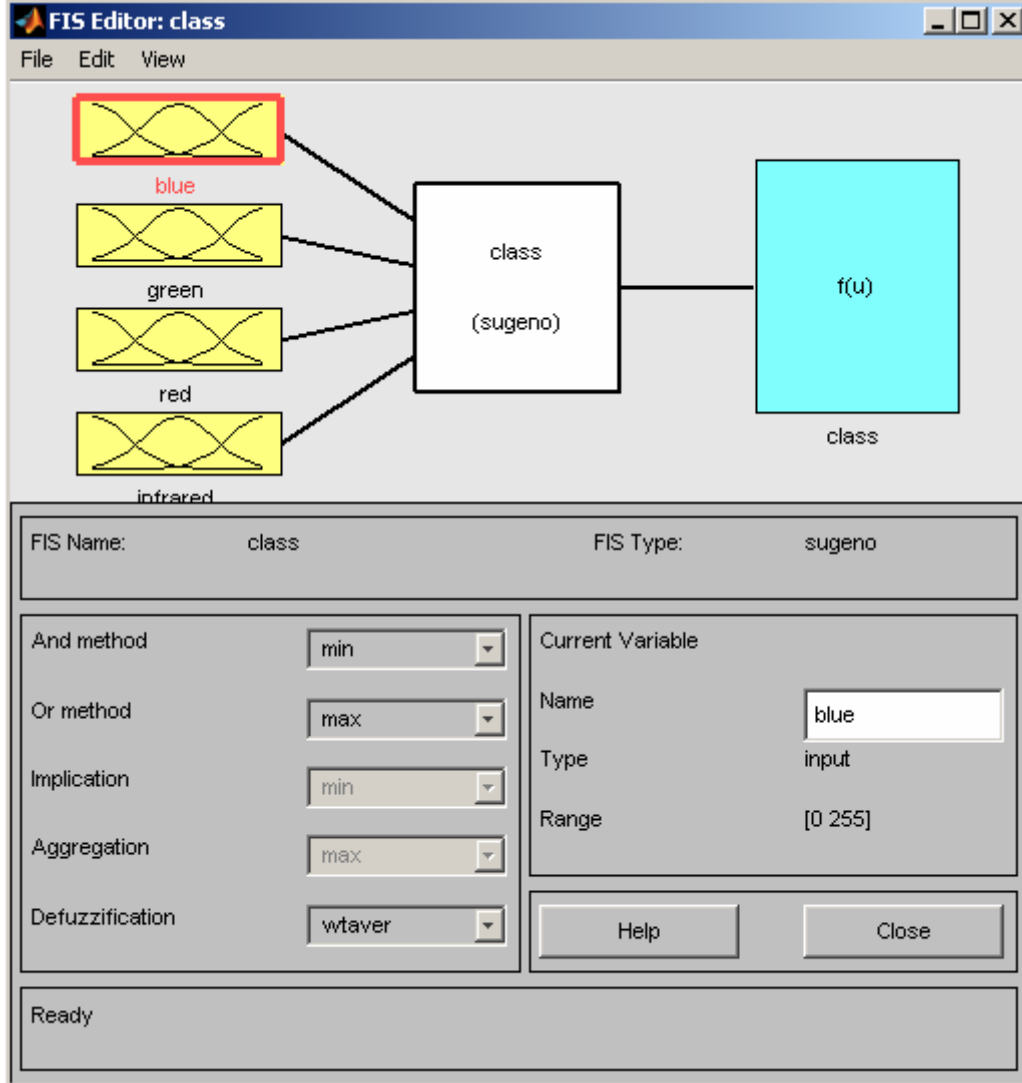


Şekil 2.19. Bulanık mantığa dayalı görüntü sınıflandırılmasında akış şeması

2.7.1. Bulanık Çıkarım Sisteminin Oluşturulması

FIS Düzenleyicisi bir bulanık çıkarım sistemi hakkında genel bilgi verir. FIS Düzenleyicisi, girdi değişkenleri (görüntü verisindeki bantlar), çıktı değişkenleri(arazi

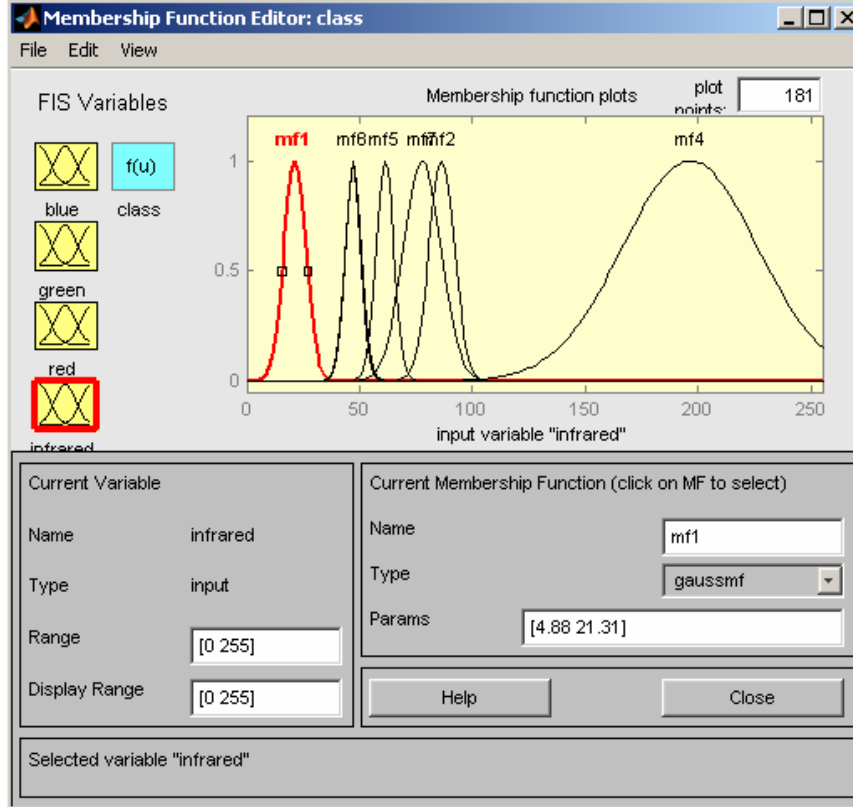
sınıfları) ve üyelik fonksiyonundan oluşmaktadır. Tez çalışmasında kullanılan uydu görüntü verisi 4 bantlı olduğundan, girdi değişkenleri mavi, yeşil, kırmızı ve kızılötesi kanalları olarak, çıktı değişkenleri arazi sınıfları olan su, yeşil 1, yeşil 2, parlak, toprak, yol ve yerleşim olarak FIS Düzenleyicisi panelinden girilmiştir.



Şekil 2.20. FIS düzenleyicisi paneli

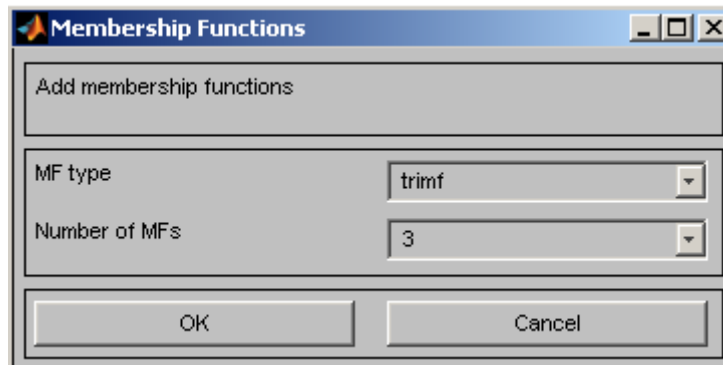
2.7.2. Üyelik Fonksiyonunun Oluşturulması

Üyelik Fonksiyonu Düzenleyicisi, tüm bulanık çıkarım sistemi için girdi ve çıktı değişkenleriyle ilişkili üyelik fonksiyonlarının düzenlenmesine ve görüntülenmesine izin veren araçtır (Şekil 2.20).



Şekil 2.21. Üyelik Fonksiyonu Düzenleyicisi Paneli

FIS’ te girdi ve çıktı değişkenleriyle ilgili üyelik fonksiyonlarını tanımlamak için FIS değişkeni seçilmelidir. Edit menüsünden ‘Add MFs’ komutuyla, üyelik fonksiyon tipini ve sayısını seçmeye izin veren yeni bir pencere açılır (Şekil 2.21).



Şekil 2.22. Üyelik fonksiyonu eklenti paneli

Üyelik fonksiyon panelinde, üyelik fonksiyonun parametresini, tipini ve ismini değiştirmeye izin veren kontroller vardır.

Tez çalışmasında üyelik fonksiyonunun tanımlanması için, düzgünlüğü ve değişkenlerinin sıfır olmamasından dolayı basit Gauss eğrisi (gaussmf) kullanılmıştır. Bu durumda, Matlab' ın Bulanık Mantık modülü üyelik fonksiyonunun tanımlanması için iki parametreye ihtiyaç duyar; bunlar, arazi sınıflarının yansıma ve standart sapma değerleridir. Bu değerler Tablo 2.8' de verilmiştir.

Tabloda, kırmızı değerler (mf_i) üyelik fonksiyonlarını göstermektedir. Örneğin, mf1 mavi, yeşil, kırmızı ve kızılötesi bantlarında su sınıfının üyelik fonksiyonunu göstermektedir. Çalışmada standart sapma değerlerinin yarısı üyelik fonksiyonu tanımlanmasında kullanılmıştır. Bunun nedeni yakın üyelik fonksiyonları arasında(mf1, mf2, ..., mf7) üst üste binmeler görülmüştür.

Çıktı değerleri için üyelik fonksiyonlarının oluşturulması tamamlanmıştır (Tablo 2.9). Değişkenler isimlendirilmiş ve kuralların yazılması işlemine geçilmiştir.

Tablo 2.8. Eğitim alanlarının ortalama yansımaya deęerleri ve standart sapma deęerleri

Kanal	Yansımaya Deęeri	Standart Sapma
<i>Su</i>		
Mavi (mf1)	35.37012	8.03559
Yeşil (mf1)	48.97299	13.30701
Kırmızı (mf1)	36.68044	14.42419
Kızılötesi (mf1)	21.31332	9.75083
<i>Yeşil 1</i>		
Mavi (mf2)	14.33396	0.7141
Yeşil (mf2)	25.57941	1.33244
Kırmızı (mf2)	22.75895	1.61433
Kızılötesi (mf2)	86.31764	11.28474
<i>Yeşil 2</i>		
Mavi (mf3)	13.42375	1.01512
Yeşil (mf3)	19.94406	1.87274
Kırmızı (mf3)	19.72137	1.97035
Kızılötesi (mf3)	47.21636	7.33155
<i>Parlak</i>		
Mavi (mf4)	142.3299	51.54414
Yeşil (mf4)	195.5361	54.07499
Kırmızı (mf4)	201.9072	53.62644
Kızılötesi (mf4)	196.4536	60.0256
<i>Toprak</i>		
Mavi (mf5)	27.2626	5.76421
Yeşil (mf5)	46.91041	8.88982
Kırmızı (mf5)	53.70269	9.59164
Kızılötesi (mf5)	61.2318	7.86034
<i>Yol</i>		
Mavi (mf6)	35.86716	4.30494
Yeşil (mf6)	49.4295	6.38832
Kırmızı (mf6)	48.00163	6.88939
Kızılötesi (mf6)	47.06927	6.85067
<i>Yerleşim</i>		
Mavi (mf7)	31.06753	4.2805
Yeşil (mf7)	51.95065	7.34335
Kırmızı (mf7)	74.75325	20.61833
Kızılötesi (mf7)	77.70779	16.58396

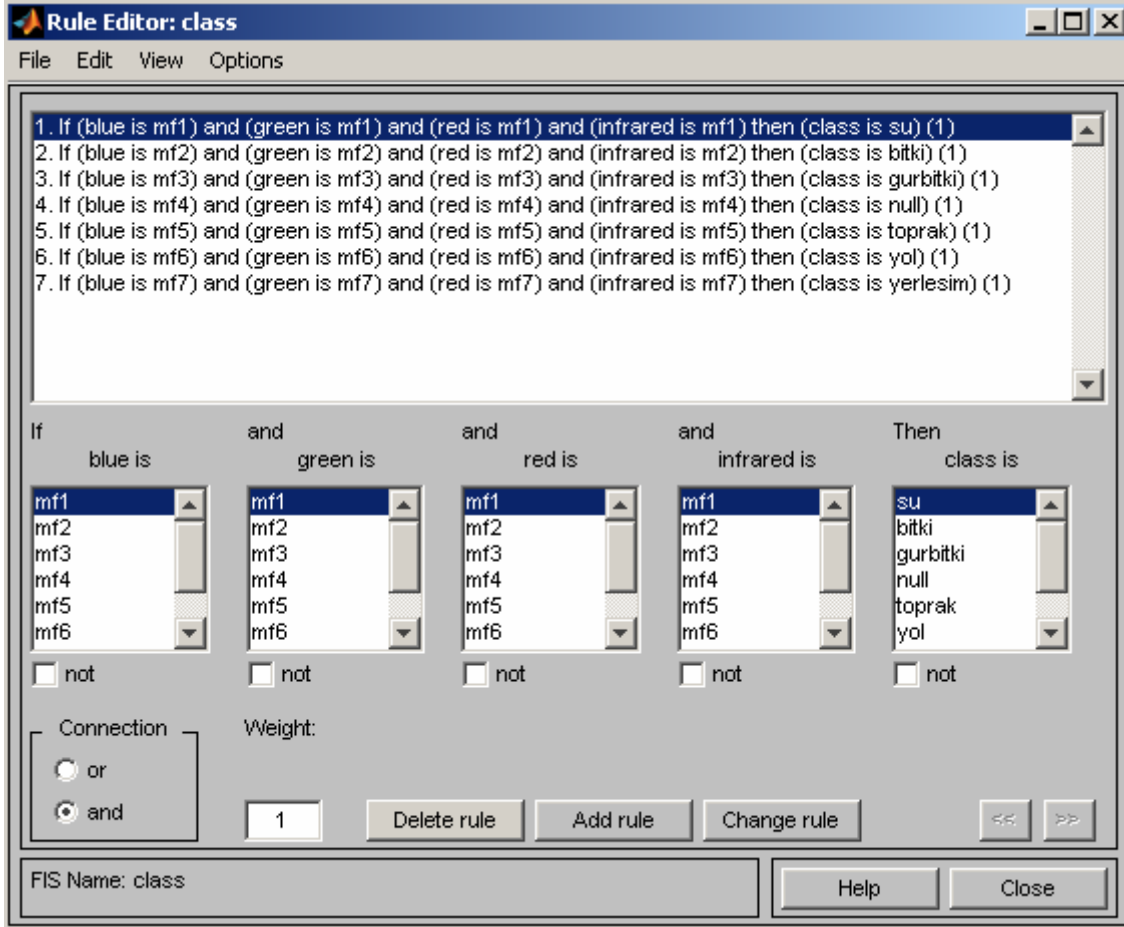
Tablo 2.9. Çıktı deęişkenlerinin parametre deęerleri

Sınıf	parametre/çıktı deęişkeni
su	1
bitki	2
gürbitki	3
null	4
toprak	5
yol	6
yerleşim	7

2.7.3. Kural Düzenleyicisinin Oluşturulması

Kural Düzenleyicisi, kural yapılarının, girdi ve çıktı deęişkenlerinin ve bağlantılarının seçilerek, otomatik olarak oluşturulmasına izin verir. Herhangi bir deęişken isminin altındaki ‘not’ seçeneğinin seçilmesi ilişkili niteliğın reddedilmesi anlamına gelir. Kurallar deęiştirilebilir, silinebilir ya da eklenebilir.

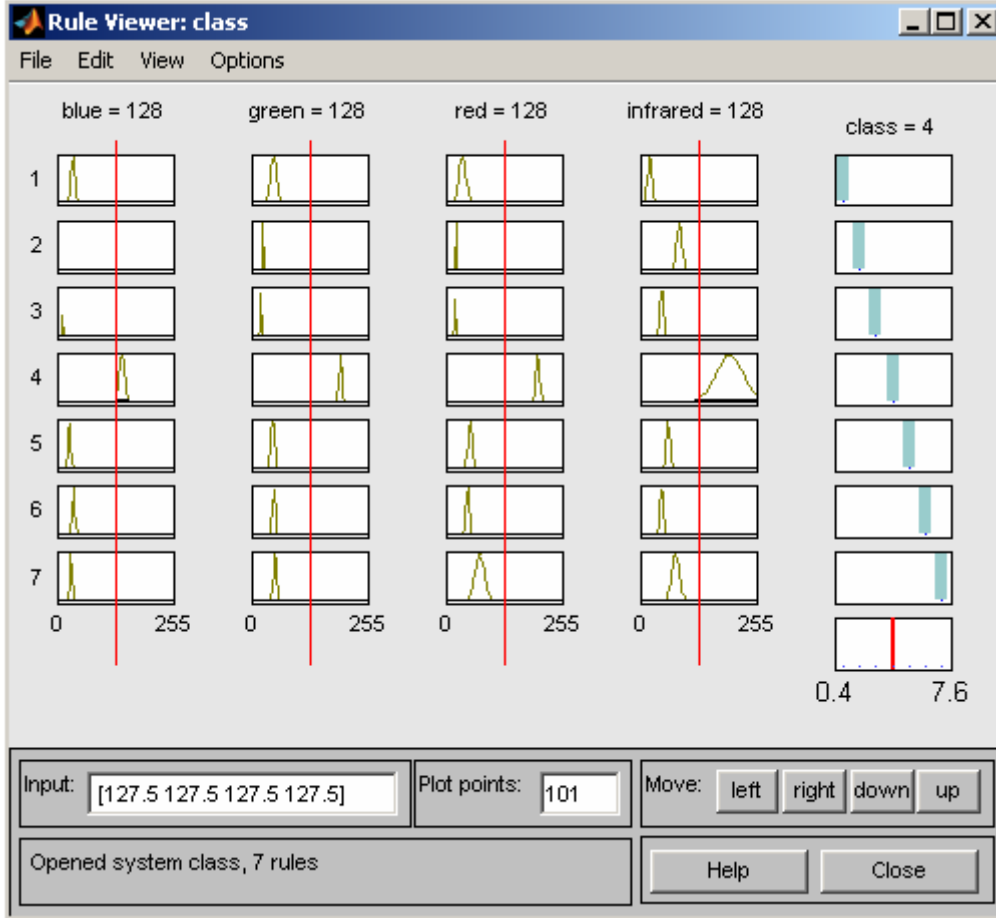
Çalışmada, bulanık çıkarım sistemi tamamlanmıştır ve ascii metin dosyası Ek 1’ de verilmiştir. Sınıfların hesaplanması için gerekli olan deęişkenler, üyelik fonksiyonları ve kurallar *fis* dosyasında tanımlıdır.



Şekil 2.23. Kural editör paneli

2.7.4. Kural Görüntüleyici

Kural Görüntüleyici, tüm bulanık çıkarım işleminin yol haritasını görüntüler. Bu, önceki bölümde açıklanan bulanık çıkarım diyagramının temelidir. 36 küçük diyagram Şekil 2.23’ de görüntülenmiştir. Çalışmada kullanılan her kural diyagramın bir sütunudur, her satır bir değişkendir. Diyagramın ilk dört sütunu (28 sarı diyagram) ilk üyelik fonksiyonlarını göstermektedir. Diyagramın beşinci sütunu (7 mavi diyagram) son üyelik fonksiyonlarını göstermektedir.



Şekil 2.24. Kural görüntüleme paneli

Diyagramlar içerisinde beşinci sütunun sekizinci diyagramı bulanık çıkarım sisteminin kararlılığını görüntülemektedir. Bu kararlılık, sistem için girdi değişkenlerine bağlıdır. Diyagramlardaki kırmızı çizgi, girdi değişkenlerinin değiştirilmesi için sürüklenebilir. Çizgi serbest bırakıldığında (ya da girdi değerleri el ile tanımlandığında), yeni bir hesap oluşturulur ve tüm bulanık çıkarım işlemi yerini alır.

Kural Görüntüleyici, tüm bulanık çıkarım sisteminin bir kerede yorumlanmasını sağlar ve üyelik fonksiyonlarının sonucu nasıl etkilediğini gösterir.

2.7.5. Sınıflandırma Aşaması ve Doğruluk Analizi

Bulanık mantığa dayalı sınıflandırma için Matlab ortamında bir program yazılmıştır ve sınıflandırma işlemi gerçekleştirilmiştir (Ek 2). 810000 pikseli görüntü, P4 2.0 GHz

işlemci ve 128MB Ram' e sahip bilgisayarda yaklaşık 35 dakikada, P4 3.0 GHz işlemci ve 1GB Ram' e sahip bilgisayarda ise yaklaşık 12 dakikada sınıflandırılmıştır.

Bulanık mantığa dayalı olarak yapılan sınıflandırmadan elde edilen sonuçlar, alana ilişkin pankromatik uydu görüntüsü kullanılarak kontrol edilmiştir. Sınıflandırmanın başarısı, Erdas Imagine 8.6 programında 210 deneme alanından oluşan nokta bazında test verisi kullanılarak kontrol edilmiştir. Uygulanan sınıflandırma sonucunda, sınıflandırmanın toplam doğruluk yüzdesi, kullanıcı ve üretici doğrulukları ile bu doğrulukların istatistiki olarak değerlendirilmesini sağlayan Kappa değerleri hesaplanmıştır. Yapılan kontrollü sınıflandırmanın başarısını özetleyecek olursak; toplam sınıflandırma doğruluğu %63,81, Kappa istatistik değeri 0,5560 olarak başarısız bulunmuştur. Kontrol esnasında her bir arazi sınıfına düşen tüm kontrol noktaları 1m çözünürlüklü pankromatik Ikonos uydu görüntüsünden kontrol edilmiş ve eğer farklı bir sınıfta ise o sınıf değeri girilmesi suretiyle görüntülerin başarısı ölçülmüştür.

Sınıflandırma sonucunun hata matrisi, genel sınıflandırma doğruluğu, kappa istatistik değerleri ve sınıfların kullanıcı ve üretici doğruluk yüzdeleri Tablo 2.10' da yer almaktadır. Sınıflandırma sonuçlarında görüldüğü gibi bulanık mantıkla yapılan sınıflandırmada başarı sağlanamamıştır. Yerleşim alanları sınıfı ile su sınıfı birbirine girmiştir. Sınıflandırmanın toplam doğruluğu çok düşüktür.

Tablo 2.10. Uydu görüntüsünün Bulanık Mantıkla yapılan sınıflandırma sonuçlarının hata matrisi

Sınıf Kodu	1	2	3	4	5	6	7	Sınıflandırılmış nokta sayısı	Üretici Doğruluğu
1	31	0	6	3	1	2	2	45	96.88
2	0	49	2	0	4	1	0	56	79.03
3	0	2	19	0	3	1	0	25	65.52
4	0	0	0	1	0	0	0	1	9.09
5	0	9	2	5	17	8	5	46	48.57
6	1	0	0	2	1	17	5	26	58.62
7	0	2	0	0	9	0	0	11	0.00
Referans Nokta Sayısı	32	62	29	11	35	29	12	210	
Kullanıcı Doğruluğu	68.89	87.5	76.00	100.0	36.96	65.38	0.00		
Kappa İstatistik Değerleri	0.633	0.8226	0.7215	1.000	0.2435	0.5984	-0.0606	0.5560	

3. BULGULAR VE İRDELEME

Tez çalışması İkonos görüntü verisi kullanılarak üç aşama şeklinde gerçekleştirilmiştir. Bunlar, maksimum olabilirlik yöntemiyle yapılan sınıflandırma, yapay sinir ağları kullanılarak yapılan sınıflandırma ve bulanık mantığa dayalı görüntü sınıflandırma uygulamalarıdır. Bu bölümde yapay sinir ağı tasarımını etkileyen parametreler ele alınıp sınıflandırma sonuçları üzerindeki etkileri araştırılmış ve diğer yöntemlerle yapılan sınıflandırma uygulamalarının sonuçları irdelenerek tüm uygulamaların sonuçları karşılaştırmalı olarak verilmiştir. Ayrıca bulanık mantığa dayalı görüntü sınıflandırma uygulamasının en kötü sonucu vermesinin nedenleri araştırılmış, bunun için Landsat uydu görüntü verisi, maksimum olabilirlik yöntemi, yapay sinir ağları yöntemi ve bulanık mantık yöntemleriyle sınıflandırılmış ve sonuçları irdelenmiştir.

3.1. Yapay Sinir Ağı Tasarımında Ağ Parametrelerinin İrdelenmesi

Bir sinir ağının eğitilmesi, ağ yapısının tanımlanması ve öğrenme parametrelerinin ayarlanması için kullanıcı etkileşimini gerektirir. Bu parametreler, iç parametreler olarak ilk önce tanımlanır ve ağ performansını etkiler. Birçok araştırmacının ağ tasarımı için farklı iç parametreleri denemelerine rağmen, günümüze kadar uygun bir ağ tasarımına karar verilebilmiş değildir. Bu faktörler arasındaki ilişkiler ve ilk ağırlık parametresi bugüne kadar keşfedilmemiştir. Bu tez çalışması kapsamında, geri yayımlı öğrenme algoritmasında, sinir ağlarının kullanılması ve tasarımı konularıyla ilgili detaylı bilgiler tartışılmış ve her parametrenin sebep olduğu sonuçları anlamak için deney sonuçları irdelenmiştir.


Ağ yapısının bileşenlerinden başlayarak, sinir ağının eğitilmesiyle ilgili önemli tüm faktörler göz önüne alınmıştır. Bu parametrelerin irdelenmesi deneme-yanılma yöntemiyle yapılmıştır.

3.1.1. Girdi Katman Sayısının İrdelenmesi

Girdi katman sayısı spektral bantlar gibi özelliklerin sayısıdır. Girdi bantlarının sayısı değiştirilerek oluşturulan ağların, sınıflandırma doğruluğu üzerindeki etkisi araştırılmıştır. Görüntü 4 bantlı olduğu için uygulamada 3 ve 4 bantlı görüntü denenmiş, ağ performansları değerlendirilerek sonuçlar Tablo 3.1 ve Şekil 3.1’ de verilmiştir.

Tablo 3.1. Girdi katman sayılarının ürettikleri toplam doğruluk sonuçları

İterasyon Sayısı	Toplam Doğruluk	
	3 band	4 band
5000	97.44	98.52
10000	97.88	97.24
15000	97.60	98.52



Şekil 3.1. Ağın eğitiminde kullanılan girdi katman sayısı ve iterasyon sayılarının toplam doğrulukta değişime etkileri


Toplam doğruluk 97.24 ile 98.52 arasında değişmektedir. Sinir ağındaki girdi katman sayısının azalması toplam doğrulukta önemli bir azalma sağlamamaktadır. Ancak, en yüksek sınıflandırma doğruluğu 4 bantlı görüntüde başarılmıştır. Aynı zamanda iterasyon sayısının ağ performansına etkisi olarak; 5000. ve 15000. iterasyonda en yüksek sınıflandırma doğruluğu gözlenmiştir.

3.1.2. Ara Katman Sayısının İrdelenmesi

Ara katman sayısı değiştirilerek oluşturulan ağların, sınıflandırma doğruluğu üzerindeki etkisi araştırılmış ve sınıflandırma sonuçları Tablo3.2 ve Şekil 3.2' de verilmiştir.

Tablo 3.2. Ara katman sayılarının ürettiği toplam doğruluk sonuçları


Ara Katman Sayısı	1	2	3	4	5	6	7	8	9
Toplam Doğruluk	53.96	92.44	94.56	97.68	98.40	98.36	98.40	98.16	98.60
Ara Katman Sayısı	10	11	12	13	14	15	16	17	
Toplam Doğruluk	98.60	98.56	98.68	98.60	98.76	98.48	98.28	98.44	
Ara Katman Sayısı	18	19	20	21	22	23	24	25	
Toplam Doğruluk	98.52	98.76	98.56	98.68	98.56	98.48	98.48	98.44	



Şekil 3.2. Görüntü verisi için ara katman sayısının sınıflandırma doğruluğu üzerindeki Etkisi

Bu sonuçlar neticesinde, düşük ara katman sayısına sahip ağ düşük sınıflandırma sonucu vermektedir. Yüksek ara katman sayısına sahip ağ kullanıldığında ise sınıflandırma

daha uzun zamanda sonuç vermektedir. Literatürde, araştırmacıların verdikleri denklemler kullanılarak ara katman sayıları hesaplanmış ve toplam doğruluktaki etkileri irdelenmiştir (Şekil 3.3). Tüm bunların sonucunda en iyi ara katman sayısının 14 olduğu ve 4. ara katman ile 25. ara katman arasındaki toplam doğruluk değerlerinin birbirine yakın olduğu gözlenmiştir.




Şekil 3.3. Tablo 1.9' da verilen bulguların performans karşılaştırmaları

3.1.3. Öğrenme Oranı ve Momentumun İrdelenmesi

Tez çalışmasında öğrenme oranı ve momentum değişiminin ağ performansına etkisi araştırılmıştır. Altı öğrenme oranı ile yedi öğrenme oranı ve momentum kullanılarak öğrenme oranı ve momentum test edilmiştir. Farklı öğrenme oranı değerleri için toplam doğruluk sonuç değerleri Tablo 3.3' te ve Şekil 3.4'te verilmiştir. Farklı öğrenme oranı ve momentum değerleri için toplam doğruluk sonuçları Tablo 3.4' te ve Şekil 3.5'te verilmiştir.

Tablo 3.3. Farklı öğrenme oranları için üretilen toplam sınıflandırma doğrulukları

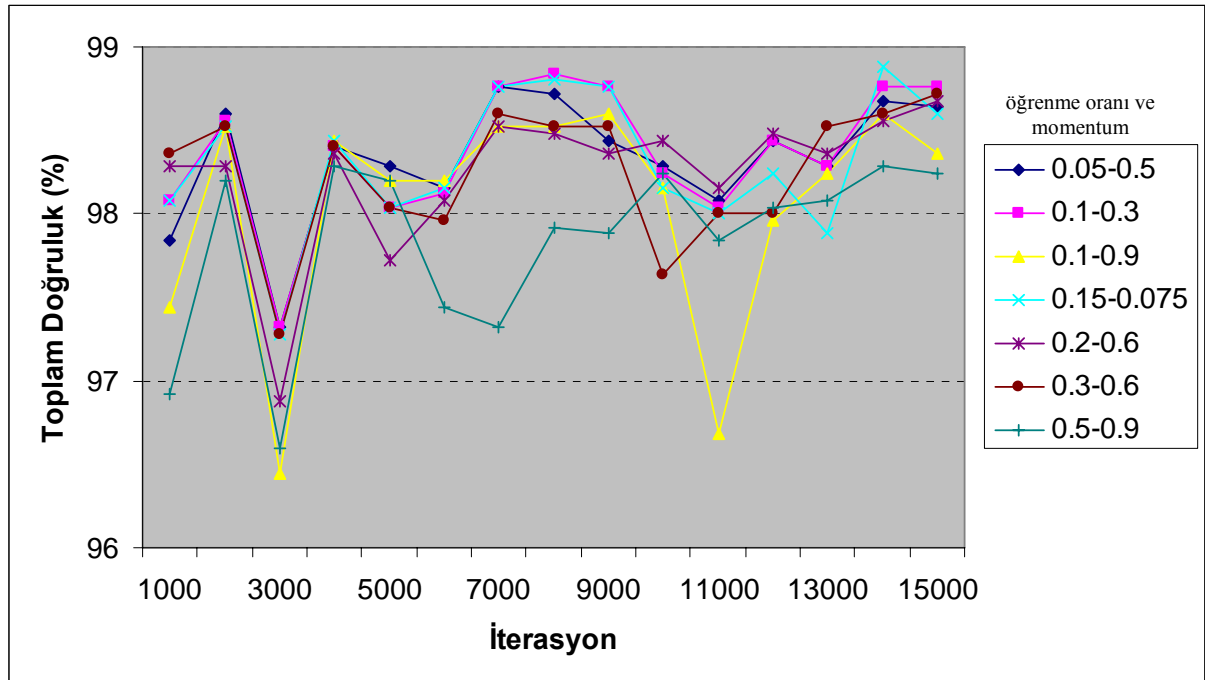
İterasyon Sayısı	Öğrenme Oranı					
	0.05	0.1	0.2	0.3	0.5	0.8
1000	97.92	98.00	98.00	98.12	98.24	98.48
2000	98.44	98.60	98.52	98.52	98.24	98.56
3000	97.24	97.36	97.52	97.04	96.88	96.92
4000	98.44	98.48	98.48	98.56	98.36	98.32
5000	98.24	98.28	98.28	97.88	97.88	97.88
6000	98.24	98.16	98.28	98.24	98.20	98.20
7000	98.72	98.76	98.68	98.56	98.40	98.60
8000	98.52	98.72	98.60	98.84	98.52	98.52
9000	98.52	98.60	98.52	98.76	98.44	98.52
10000	98.48	98.28	98.04	98.24	98.12	97.88
11000	98.32	98.08	98.24	98.00	98.20	97.92
12000	98.28	98.48	98.48	98.24	98.36	97.92
13000	98.52	98.28	98.56	98.28	98.24	97.60
14000	98.52	98.64	98.68	98.84	98.40	98.20
15000	98.56	98.64	98.64	98.72	98.48	98.24



Şekil 3.4. Farklı öğrenme oranları için üretilen toplam sınıflandırma doğrulukları analizi

Tablo 3.4. Farklı öğrenme oranları ve momentumlar için üretilen toplam sınıflandırma doğrulukları

İterasyon Sayısı	Öğrenme Oranı ve Momentum						
	0.05 - 0.5	0.1 - 0.3	0.1 - 0.9	0.15 - 0.075	0.2 - 0.6	0.3 - 0.6	0.5 - 0.9
1000	97.84	98.08	97.44	98.08	98.28	98.36	96.92
2000	98.60	98.56	98.52	98.52	98.28	98.52	98.20
3000	97.32	97.32	96.44	97.28	96.88	97.28	96.60
4000	98.40	98.40	98.44	98.44	98.36	98.40	98.28
5000	98.28	98.04	98.20	98.04	97.72	98.04	98.20
6000	98.16	98.12	98.20	98.16	98.08	97.96	97.44
7000	98.76	98.76	98.52	98.76	98.52	98.60	97.32
8000	98.72	98.84	98.52	98.80	98.48	98.52	97.92
9000	98.44	98.76	98.60	98.76	98.36	98.52	97.88
10000	98.28	98.24	98.16	98.16	98.44	97.64	98.24
11000	98.08	98.04	96.68	98.00	98.16	98.00	97.84
12000	98.44	98.44	97.96	98.24	98.48	98.00	98.04
13000	98.28	98.28	98.24	97.88	98.36	98.52	98.08
14000	98.68	98.76	98.60	98.88	98.56	98.60	98.28
15000	98.64	98.76	98.36	98.60	98.68	98.72	98.24

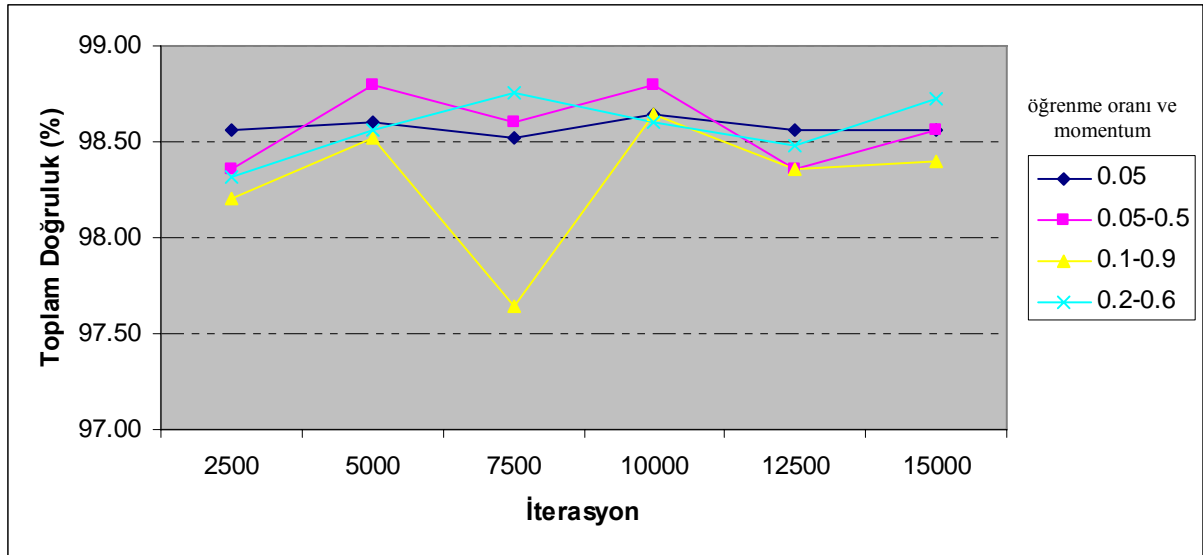


Şekil 3.5. Farklı öğrenme oranları ve momentumlar için üretilen toplam sınıflandırma doğrulukları analizi


Tablolarda, Şekil 3.4 ve Şekil 3.5’te düşük değerlere sahip öğrenme oranlarının tutarlı ve doğru sonuçlar ürettiği görülmektedir. Yüksek değerlere sahip öğrenme oranlarının salınımlı ve tutarsız olduğu görülmektedir. Şekil 3.4’te görüldüğü gibi 0.3 öğrenme oranlı ağ en yüksek doğruluklu sınıflandırma üretmiştir. Ayrıca 0.15 öğrenme oranlı 0.075 momentumlu ağ en yüksek doğruluklu sınıflandırmayı gerçekleştirmiştir. Tam aksine 0.8 öğrenme oranlı ağ en düşük doğruluklu sınıflandırmayı gerçekleştirmiştir. Eğer öğrenme oranı çok büyük ayarlanırsa, sistem kararsız olup hataya doğru yakınsamaktadır. Eğer öğrenme oranı çok küçük ayarlanırsa, küçük adımlar alınıp, sınıflandırma daha uzun zamanda sonuç vermektedir.

3.1.4. İlk Ağırlık Parametresinin İrdelenmesi


Çalışmada, en uygun ilk ağırlık parametresine karar verebilmek için farklı öğrenme oranları ve momentumlarda sınıflandırma sonuçları üretilmiş ve Şekil 3.6, Şekil 3.7, Şekil 3.8, Şekil 3.9, Şekil 3.10 ve Şekil 3.11’ de verilmiştir.




Şekil 3.6. İlk ağırlığı $[0, 1]$ ’ e bağlı olarak üretilen sınıflandırma doğruluğundaki değişimler




Şekil 3.7. İlk ağırlığı $[-0.1, 0.1]$ ' e bağlı olarak üretilen sınıflandırma doğruluğundaki değişimler




Şekil 3.8. İlk ağırlığı $[-0.15, 0.15]$ ' e bağlı olarak üretilen sınıflandırma doğruluğundaki değişimler



Şekil 3.9. İlk ağırlığı $[-0.25, 0.25]$ ' e bağlı olarak üretilen sınıflandırma doğruluğundaki değişimler



Şekil 3.10. İlk ağırlığı $[-0.3, 0.3]$ ' e bağlı olarak üretilen sınıflandırma doğruluğundaki değişimler



Şekil 3.11. İlk ağırlığı [-0.5, 0.5]' e bağlı olarak üretilen sınıflandırma doğruluğundaki değişimler


Yapılan deneyler sonucunda, ilk ağırlık parametresi [-0.1, 0.1] aralığında en iyi sınıflandırma sonucunu vermektedir.

3.1.5. Çıktı Kodlamasının İrdelenmesi

Çalışmada [0 1 0], [0.01 0.99 0.01], [0.1, 0.9, 0.1] ve [0.003, 0.99, 0.003] çıktı kodlamalarının sınıflandırma doğruluğu üzerindeki etkileri araştırılmıştır. Sınıflandırma sonuçları Tablo 3.5' te ve Şekil 3.12' de verilmektedir.

Tablo 3.5. Çıktı kodlamalarının ürettikleri sınıflandırma sonuçları

İterasyon Sayısı	Çıktı Kodlaması			
	[0 1 0]	[0.01 0.99 0.01]	[0.1 0.9 0.1]	[0.003 0.99 0.003]
1000	98.08	98.12	98.04	98.08
2000	98.56	98.60	98.20	98.56
3000	97.40	97.44	97.52	97.40
4000	98.52	98.48	98.24	98.48
5000	97.92	97.92	97.96	97.92
6000	98.16	98.08	98.04	98.08
7000	98.68	98.68	98.28	98.72
8000	98.84	98.72	98.08	98.80
9000	98.80	98.72	97.84	98.76
10000	98.32	98.20	98.28	98.32
11000	98.28	98.08	97.76	98.20
12000	98.32	98.28	97.76	98.32
13000	98.20	98.12	98.04	98.20
14000	98.88	98.92	97.88	98.88
15000	98.68	98.68	98.40	98.68



Şekil 3.12. Farklı kodlama metotlarının sınıflandırma doğruluğuna etkileri

[0.1 0.9 0.1] kodlaması hariç diğer tüm çıktı kodlamaları birbirine yakın sonuçlar üretmiştir. En uygun çıktı kodlaması [0 1 0] olarak belirlenmiştir.

3.1.6. Yapay Sinir Ağları İçin En İyi Tasarımın Belirlenmesi

Yapay Sinir Ağı tasarımında tüm parametrelerin irdelenmesi sonucunda, İkonos görüntü verisinde en iyi tasarım için gerekli parametreler belirlenmiştir. Tablo 3.6' da en iyi yapay sinir ağı tasarımı gösterilmektedir.

Tablo 3.6. İkonos görüntü verisinde YSA tasarımı için en iyi ayarlar

Parametreler	Seçim
Girdi katman sayısı	4
Çıktı katman sayısı	7
Ara katman sayısı	14
İlk ağırlık aralığı	[-0.1, 0.1]
Momentumsuz öğrenme oranı	0.3
Momentumlu öğrenme oranı	0.15 – 0.075
Çıktı kodlaması	[0 1 0]

3.2. Landsat Uydu Görüntü Verisi Kullanılarak Yapılan Sınıflandırmaların İrdelenmesi

Trabzon iline ait Landsat uydu görüntü verisi toplam 3 kanaldan ve 900 x 900 pikselden oluşmaktadır. Hedef sınıfları en iyi derecede temsil edecek şekilde seçilen eğitim veri kümesi 4 sınıftan oluşmaktadır. Bu sınıflar, deniz ve dereleri temsil eden su, bitki örtüsü yoğunluğunun az olduğu alanları temsil eden yeşil1, bitki örtüsünün yoğun olduğu alanları temsil eden yeşil2 ve yerleşim ve parlak alanları temsil eden parlak olarak belirlenmiştir. Bu sınıflar kullanılarak, uydu görüntü verisi maksimum olabilirlik yöntemi, bulanık mantığa dayalı görüntü sınıflandırma yöntemi ve yapay sinir ağları yöntemleriyle sınıflandırılmıştır.

İkonos uydu görüntü verisi kullanılarak yapılan sınıflandırma uygulamasında en iyi sonuçları sırasıyla yapay sinir ağları yöntemi, maksimum olabilirlik yöntemi ve bulanık mantık yöntemleri vermiştir. Landsat uydu görüntü verisi kullanılarak yapılan sınıflandırma uygulamasında ise en iyi sonucu gene YSA ile yapılan sınıflandırma vermiştir. Ancak, İkonos görüntü verisinden farklı olarak bulanık mantığa dayalı görüntü

sınıflandırma uygulaması maksimum olabilirlik yönteminden daha iyi sonuç vermiştir. Bu sonuçlar tezin genel karşılaştırma bölümünde verilmiştir.

3.3. Genel Karşılaştırma

İkonos ve Landsat görüntü verileri için genel doğruluk, kappa ve üretici doğruluk değerleri, Yapay Sinir Ağları, Bulanık Mantık ve Maksimum Olabilirlik sınıflandırma uygulamaları için karşılaştırmalı olarak Tablo 3.7 ve Tablo 3.8’ de verilmiştir.


Tablo 3.7. İkonos uydu görüntü verisi için bütün sınıflandırma yöntemlerinin GD, Kappa ve üretici doğruluk değerleri

	Sınıflar / Üretici Doğrulukları								
	GD	Kappa	1	2	3	4	5	6	7
MO	67.62	60.20	96.43	77.46	65.22	80.00	63.89	46.15	12.50
YSA	98.76	98.55	100	98.67	99.46	100	96.75	98.92	97.00
BM	63.81	55.60	96.88	79.03	65.52	9.09	48.57	58.62	0.00

Tablo 3.8. Landsat uydu görüntü verisi için bütün sınıflandırma yöntemlerinin GD, Kappa ve üretici doğruluk değerleri


	Sınıflar / Üretici Doğrulukları					
	GD	Kappa	1	2	3	4
MO	68.33	52.90	73.91	70.77	59.26	60.00
YSA	100.00	100.00	100.00	100.00	100.00	100.00
BM	75.23	61.80	79.41	55.38	77.07	78.95

İkonos görüntü verisi için sınıflandırılmış görüntüler Şekil 3.13, Şekil 3.14, Şekil 3.15’ te, Landsat görüntü verisi için sınıflandırılmış görüntüler Şekil 3.16, Şekil 3.17 ve Şekil 3.18’ de verilmiştir.




■	Su
■	Yeşil 1
■	Yeşil 2
□	Parlak
■	Toprak
■	Yol
■	Yerleşim

Şekil 3.13. Ikonos görüntü verisi için Maksimum Olabilirlik yöntemi ile yapılan sınıflandırma sonuç görüntüsü




■	Su
■	Yeşil 1
■	Yeşil 2
□	Parlak
■	Toprak
■	Yol
■	Yerleşim

Şekil 3.14. İkonos görüntü verisi için Bulanık Mantık yöntemi ile yapılan sınıflandırma sonuç görüntüsü




■	Su
■	Yeşil 1
■	Yeşil 2
□	Parlak
■	Toprak
■	Yol
■	Yerleşim

Şekil 3.15. İkonos görüntü verisi için Yapay Sinir Ağları ile yapılan sınıflandırma sonuç görüntüsü




■	Su
■	Yeşil 1
■	Yeşil 2
□	Parlak

Şekil 3.16. Landsat görüntü verisi için Maksimum Olabilirlik yöntemi ile yapılan sınıflandırma sonuç görüntüsü



■	Su
■	Yeşil 1
■	Yeşil 2
□	Parlak

Şekil 3.17. Landsat görüntü verisi için Bulanık Mantık yöntemi ile yapılan sınıflandırma sonuç görüntüsü



■	Su
■	Yeşil 1
■	Yeşil 2
□	Parlak

Şekil 3.18. Landsat görüntü verisi için Yapay Sinir Ağları ile yapılan sınıflandırma sonuç görüntüsü

4. SONUÇLAR VE ÖNERİLER

Bu çalışmada, sınıflandırma problemi için gerçekleştirilen uygulamalar sonucunda, YSA yapısından elde edilen sınıflandırma genel doğruluk (GD) ve Kappa değerlerinin, maksimum olabilirlik ve bulanık mantık yöntemlerinden elde edilen değerlerden daha yüksek çıktığı görülmüştür.

Maksimum olabilirlik yönteminde test verileri için elde edilen sınıflandırma doğruluk değerinin YSA doğruluk değerlerinden düşük olması, bu yöntemin eğitim verisi dışında karşılaştığı diğer veriler için rölatif olarak daha az bir genelleme yeteneğine sahip olduğunu göstermektedir. Burada MO yönteminin en büyük özelliği sınıflandırma verisi için istatistiksel dağılım (Gauss) kabulü yapmasıdır. Verinin bu dağılıma uymaması, bu dağılımdan sapması ölçüsünde sınıflandırma performansı düşecektir. MO yönteminin diğer önemli bir özelliği ise oluşan sınıf karar sınırlarının, her bir eğitim verisine ait istatistiksel parametrelerin bağımsız olarak kullanılmasıyla elde edilmesidir.

Çalışmada, bulanık mantık uygulaması için yeterli sayıda veri seçilmiş ve bu verilere ait uygun üyelik dereceleri ve alt küme aralıkları belirlenmiştir. Bulanık mantık yöntemiyle yapılan sınıflandırma uygulaması, Ikonos uydu görüntü verisi için çalışmada en kötü sonucu vermiştir, ancak Landsat uydu görüntü verisi için MO yönteminden daha iyi sonuç verdiği görülmüştür. Bu da gösteriyor ki, seçilen sınıf ve uydu görüntüsüne bağlı olarak MO yöntemi ve bulanık mantık yöntemi doğruluk dereceleri açısından yer değiştirebiliyor. Bulanık mantığın esnek hesaplama yöntemine sahip olması ve klasik yöntemler gibi üyelik değerlerinin 0 ya da 1 şeklinde olmayıp 0 ile 1 arasında değişen üyelik değerleri ile ifade edilmeleri bu yöntemi her zaman cazip kılmaktadır.

Çalışmada kullanılan geri yayımlı YSA uygulamasında, bütün ağ yapılarının genel doğruluk, Kappa ve üretici doğruluk değerleri hesaplanmıştır. Sınıflandırma problemi için en uygun ağ yapısı sınıflandırma GD değerlerine göre belirlenmiş ve ağ tasarımıyla ilgili sonuçlar aşağıda sıralanmıştır.

- Girdi katman sayısı için doğru sayıyı tespit etmede, farklı boyuttaki giriş tabakasını değerlendirmekten başka yol bulunmamaktadır.

- Ara katman sayısını tahmin etmek için literatürde çok sayıda yöntem bulunmasına rağmen, bunların çok azı, bu araştırma çalışmasında dikkate alınan problemler için güvenilir bulunmaktadır. Garson tarafından önerilen yöntemin, diğerlerinden daha yüksek seviyelerde doğruluk payı olan sonuçlar ortaya koyduğu saptanmıştır. Bunun nedenlerinden birisi, problemin zorluğu ile ilgili olan, kullanıcı tarafından tanımlanan bir r sabitini içermesidir. Bu, bir esneklik derecesi ortaya koymakta ve sınıflandırma probleminin karmaşıklığı değiştikçe ağ büyüklüğünün uyum göstermesine izin vermektedir.
- Ağ performansındaki ara katman sayısının değiştirilmesi, sinir ağlarının küçük ağ boyutlarına aşırı duyarlılığını ve büyük ağ boyutlarına duyarsızlığını göstermektedir. Diğer bir deyişle, sınıflandırma doğruluğu ara katman sayısının fazla olduğu durumlarda neredeyse aynı kalırken, ara katman sayısının çok küçük olduğu durumda sınıflandırma doğruluğunda önemli bir azalma gözlenmektedir.
- Öğrenme oranı ve momentum parametrelerinin değerleri için çok sayıda kombinasyon önerilmiştir. Bu önerilerin bazılarının azaltılmış performansla sonuçlandıkları saptanmıştır. Bu çalışmada, 0.3'lük bir öğrenme oranı ya da 0.075'lik bir momentum değerine sahip 0.15'lik bir öğrenme oranı, daha yüksek sınıflandırma doğruluğu değerlerine yol açabilmektedir.
- Küçük ilk ağırlık parametreleri, büyük ilk ağırlık parametrelerinden daha yüksek sınıflandırma doğruluğu değerleri ortaya koymaktadır. Ancak, sınıflandırma doğruluğu seviyelerindeki farklılıklar genellikle küçüktür.
- Önerilmiş birkaç çıktı kodlama stratejisi, seçilmiş bir sınıfa karşılık gelen düğüme 1, diğer sınıfları temsil eden düğümlere de 0'ın verildiği geleneksel şifreleme planı [0 1 0]'la karşılaştırılmıştır. Elde edilen sonuçlardan, [0 1 0] geleneksel çıktı kodlaması en iyi sonucu vermektedir ve bu kodlama önerilmektedir.

İkonos görüntü verisi için elde edilen bu sonuçlar, yapay sinir ağlarıyla görüntü sınıflandırmasındaki tasarım sürecini ve kullanımını kolaylaştıracak bir rehber oluşturmaktadır. Bu rehber, kullanıcıya, ağ yapısını tanımlama ve öğrenme algoritmasını düzenleme fırsatı vermektedir. Bunların, bu araştırmada kullanılan benzer veri kümeleri ve sınıflandırma problemleri için geçerli olduğu belirtilmelidir. Ağ tasarımında, kullanıcılara kolaylık sağlayacak rehber aşağıda verilmiştir:

- $N_p / [r(N_i + N_o)]$ Garson formülü kullanılarak gerekli olan ara katman sayısının hesaplanması,
- Görüntü verisinin doğası göz önünde bulundurularak, çıktı tabaka sayısının tanımlanması,
- İlk ağırlık parametrelerinin, düşük değerde bir aralığa ayarlanması (örneğin [-0.1, 0.1] ya da [-0.15, 0.15]),
- Sadece öğrenme oranı için 0.3, öğrenme oranı ve momentum için ise 0.15 – 0.075 değerlerinin kullanılması,
- Çıkış sınıflarını temsil etmek için [0 1 0]'lık çıkış kodlama tekniğinin kullanılması.

Bu çalışmada gerçekleştirilen uygulamalar, YSA sınıflandırma algoritmasının çok spektrumlu uydu görüntü verilerinin sınıflandırılması için bulanık mantık ve klasik yöntemlere göre kıyaslanabilir ve daha iyi performans gösteren etkin sınıflandırma araçları olduklarını göstermiştir. Buna karşın sinir ağları ile sınıflandırma işlemi, standart yöntemlere oranla hem zaman alıcı hem de daha çok uğraş gerektiren bir araç durumundadır. Yakın bir gelecekte sinir ağlarının kullanımı kolay ve standart bir araç olacağını tahmin etmek zor değildir.

5. KAYNAKLAR

- Akyılmaz O., Ayhan T., 2003. Bulanık Mantık ve Jeodezide Uygulama Alanları, 9. Türkiye Harita Bilimsel ve Teknik Kurultayı, Bildiriler Kitabı, Ankara, 377-385.
- Altaş, İ. H., 1999. Bulanık Mantık: Bulanıklık Kavramı, Enerji, Elektrik, Elektromekanik-3e, 62, 80-85.
- Ayhan, E., Karşlı, F., Tunç E., 2003. Uzaktan Algılanmış Görüntülerde Sınıflandırma ve Analiz, Harita Dergisi.
- Coşkun G., 1992. Uydu Verileri ile İstanbul Boğazı ve Haliç' te Su Kirliliğinin Makro Düzeyde Belirlenmesi, Doktora Tezi, İstanbul.
- Çetin, M., 2001. Açık Maden İşletmelerinde Maden Yatakları Üzerindeki Değişmelerin Multi-Temporal Landsat TM Görüntüleri Kullanılarak İzlenmesi, Yüksek Lisans Tezi, Gebze.
- Demirel, O., 1999. Bulanık Mantık, Bilim ve Teknik Dergisi , 385, 78-80.
- Erdas Field Guide, 2002. Erdas Imagine 8.6 User Guide.
- Erler, M., 1999. Dikdörtgen Mikroşerit Antenlerin Yapay Sinir Ağları İle Analizi ve Tasarımı, Doktora Tezi, Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Kayseri.
- Foody, G.M., 2002. Status of Land Cover Classification Accuracy Assesment, Remote Sensing Environment 80: 185-201
- Geomatica Prime Help, 2003. PCI Geomatica 9.0 User Guide.
- Göksel, Ç., 1996. Elmalı ve Alibey Su Havzalarının Uydu Görüntü Verileriyle İzlenmesi ve Bilgi Sistemi Oluşturma Olanakları, Doktora Tezi, İstanbul.
- Haykin, S., 1999. Neural Networks A Comprehensive Foundation, Prentice Hall International Inc, USA.
- Hellman, M., Fuzzy Logic Introduction, [www.fpk.tu.berlin.de / ~anderl / epsilon / fuzzyintro4.pdf](http://www.fpk.tu.berlin.de/~anderl/epsilon/fuzzyintro4.pdf), 03 Ocak 2004.
- Jehnsen, J.R., 1996. Introductory Digital Image Processing, A Remote Sensing Perspective, Prentice Hall, New Jersey.
- Kavzoglu, T., 1999. Determining Optimum Structure for Artificial Neural Networks, Proceedings of the 25th Annual Technical conference and Exhibition of the Remote Sensing Society (Earth Observation: From Data to Information), Cardiff, UK, 675-682.

- Kavzođlu, T., 2001. An Investigation of The Design And Use of Feed-Forward Artificial Neural Networks In The Classification of Remotely Sensed Images, Phd Thesis, University of Nottingham, England.
- Kavzođlu, T., 2002. G.Y.T.E Uzaktan Algılama 1 Ders Notları (yayınlanmamış), G.Y.T.E Yüksek Lisans Programı, Gebze.
- Lillesand, T.M., Kiefer, R.W., 2000. Remote Sensing and Image Interpretation, John Wiley&Sons Inc., New York.
- Mathworks Inc., 1998. Matlab Fuzzy Logic Toolbox, Users Guide.
- Örmeci ,C., 1987. Uzaktan Algılama (Temel Esaslar ve Algılama Sistemleri) Cilt 1, İ.T.Ü. Matbaası, İstanbul.
- Özkan, C., 2001. Uydu Görüntü Verilerinin Yapay Sinir Ağları ile Sınıflandırılması, Doktora Tezi, İstanbul.
- Sabins, F.F., 1987. Remote Sensing: Principles and Interpretation, Freeman, New York.
- Sađırođlu, Ő., BeŐdok, E., Erlen, M., 2003. Mühendislikte Yapay Zeka Uygulamaları, Ufuk Kitabevi, İstanbul.
- Samadzadegan, F., Azizi, A., Lucas, C. ve Hann, M., 2002. Automatic Surface Reconstruction based on the Fusion of Fuzzy Logic and Robust Estimation Techniques, Photogrammetric record, 17, 100, 651-674.
- Szymanski, D.L., 1998. A Strategy Improve Forest Cover Classification Accuracy in New York Using Landsat and Ancillary Data, Master Thesis, State University of New York, New York.
- Yılmaz, M., Arslan, E., 2005. Bulanık Mantığın Jeodezik Problemlerin Çözümünde Kullanılması, 2. Mühendislik Ölçmeleri Sempozyumu, İstanbul.
- Yurtođlu, H., 2005. Yapay Sinir Ağları Metodolojisi İle Öngörü Modellemesi: Bazı Makroekonomik Deđişkenler İçin Türkiye Örneđi, DPT Uzmanlık Tezi, Ankara.
- URL- 1, <http://www.sieurasia.com/ikonos.htm>, 10 Őubat 2006.
- URL- 2, www.berkeley.edu, 24 Ocak 2006.
- URL- 3, <http://www.mathworks.com/access/helpdesk/help/toolbox/fuzzy/>, 10 Mart 2006.
- URL-4, <http://www.cems.uwe.ac.uk/~xzhang/PDF/MSc/Fuzzy%20Logic.pdf>, 29 Mart 2006
- URL- 5, http://www.dacs.dtic.mil/techs/neural/neural_ToC.html, 13 Nisan 2006

6. EKLER

```
[System]
Name='class'
Type='sugeno'
Version=2.0
NumInputs=4
NumOutputs=1
NumRules=7
AndMethod='min'
OrMethod='max'
ImpMethod='prod'
AggMethod='sum'
DefuzzMethod='wtaver'
```

```
[Input1]
Name='blue'
Range=[0 255]
NumMFs=7
MF1='mf1': 'gaussmf', [4.02 35.37]
MF2='mf2': 'gaussmf', [0.36 14.33]
MF3='mf3': 'gaussmf', [0.51 13.42]
MF4='mf4': 'gaussmf', [6.3 142.33]
MF5='mf5': 'gaussmf', [2.88 27.26]
MF6='mf6': 'gaussmf', [2.15 35.87]
MF7='mf7': 'gaussmf', [2.14 31.07]
```

```
[Input2]
Name='green'
Range=[0 255]
NumMFs=7
MF1='mf1': 'gaussmf', [6.65 48.97]
MF2='mf2': 'gaussmf', [0.67 25.58]
MF3='mf3': 'gaussmf', [0.94 19.94]
MF4='mf4': 'gaussmf', [3.2 195.54]
MF5='mf5': 'gaussmf', [4.44 46.91]
MF6='mf6': 'gaussmf', [3.19 49.43]
MF7='mf7': 'gaussmf', [3.67 51.95]
```

```
[Input3]
Name='red'
Range=[0 255]
NumMFs=7
```

Ek 1. Matlab' ta bulanık çıkarım sistemi yapısı

Ek 1' in devamı

```
MF1='mf1':'gaussmf',[7.21 36.68]
MF2='mf2':'gaussmf',[0.81 22.76]
MF3='mf3':'gaussmf',[0.99 19.72]
MF4='mf4':'gaussmf',[4.5 201.91]
MF5='mf5':'gaussmf',[4.8 53.7]
MF6='mf6':'gaussmf',[3.44 48]
MF7='mf7':'gaussmf',[10.31 74.75]
```

[Input4]

```
Name='infrared'
Range=[0 255]
NumMFs=7
MF1='mf1':'gaussmf',[4.88 21.31]
MF2='mf2':'gaussmf',[5.64 86.32]
MF3='mf3':'gaussmf',[3.67 47.22]
MF4='mf4':'gaussmf',[30.01 196.45]
MF5='mf5':'gaussmf',[3.93 61.23]
MF6='mf6':'gaussmf',[3.43 47.07]
MF7='mf7':'gaussmf',[8.29 77.71]
```

[Output1]

```
Name='class'
Range=[1 7]
NumMFs=7
MF1='su':'constant',[1]
MF2='bitki':'constant',[2]
MF3='gurbitki':'constant',[3]
MF4='null':'constant',[4]
MF5='toprak':'constant',[5]
MF6='yol':'constant',[6]
MF7='yerlesim':'constant',[7]
```

[Rules]

```
1 1 1 1, 1 (1) : 1
2 2 2 2, 2 (1) : 1
3 3 3 3, 3 (1) : 1
4 4 4 4, 4 (1) : 1
5 5 5 5, 5 (1) : 1
6 6 6 6, 6 (1) : 1
7 7 7 7, 7 (1) : 1
```

```
B=imread('blue.tif');
G=imread('green.tif');
R=imread('red.tif');
I=imread('infrared.tif');
n=900;
m=900;
a=readfis('class');
for i=1:n
    for k=1:m
        j1=B(i,k);
        j2=G(i,k);
        j3=R(i,k);
        j4=I(i,k);
        if((j1==0) & (j2==0) & (j3==0) & (j4==0));
            ov(i,k)=0;
        else
            D=[j1 j2 j3 j4];
            H=double(D);
            z=evalfis(H,a);
            ov(i,k)=z;
        end
    end
end
F=uint8(round(ov));
imwrite(F, 'fuzzy4.tif');
```

Ek 2. Bulanık mantığa dayalı görüntü sınıflandırılması için Matlab' ta yazılan kod

ÖZGEÇMİŞ

1981 yılında İzmir ili Bornova ilçesinde doğdu. İlkokulu Aydoğdu İlkokulu'nda, ortaokul ve lise öğrenimini de Karşıyaka Atakent Anadolu Lisesinde tamamladı. 1999 yılında başladığı Karadeniz Teknik Üniversitesi Jeodezi ve Fotogrametri Mühendisliği Bölümünden 2003 yılında mezun oldu. Aynı yıl K.T.Ü Fen Bilimleri Enstitüsü Jeodezi ve Fotogrametri Mühendisliği Anabilim dalında Yüksek lisans öğrenimine başladı. Ekim 2005'de Ağrı Kadastro Müdürlüğü' ne Harita Mühendisi olarak atandı. Halen bu görevini sürdürmektedir.