

**UYDU GÖRÜNTÜ VERİSİNİN
YAPAY SİNİR AĞLARI İLE SINIFLANDIRILMASI**

DOKTORA TEZİ
Y.Müh. Coşkun ÖZKAN
501982611

112235

T.C. YÜKSEKÖĞRETİM KURULU
DOKÜMANTASYON MERKEZİ

Tezin Enstitüye Verildiği Tarih : 22 Mayıs 2001
Tezin Savunulduğu Tarih : 16 Kasım 2001

Tez Danışmanı : Doç.Dr. Filiz SUNAR ERBEK

Diğer Jüri Üyeleri Prof.Dr. Derya MAKTAV (İ.T.Ü.)

Prof.Dr. Gönül TOZ (İ.T.Ü.)

Yrd.Doç.Dr. Süha BERBEROĞLU (Ç.Ü.)

Yrd.Doç.Dr. Erkan BEŞDOK (E.Ü.)

KASIM 2001

ÖNSÖZ

Değerli zamanlarını ayırarak danışmanlığımı üstlenen ve çok yoğun çalışma ortamına rağmen bütün çalışmalarında güvenini esirgemeyen, her türlü desteği veren ve yol gösteren hocam sayın Doç.Dr. Filiz Sunar ERBEK hanımefendiye değerli teşvik ve katkılarından dolayı şükranlarımı sunarım.

Tez izleme jüri üyeliğini kabul ederek çalışmalarına çok değerli katkı ve yardımlarda bulunan hocalarım sayın Prof.Dr. Derya MAKTAV ve sayın Yrd.Doç.Dr. Süha BERBEROĞLU beyefendilere çok teşekkür ederim.

Çalışmalarında desteklerini ve yardımlarını esirgemeyen Erciyes Üniversitesi Jeodezi ve Fotogrametri Mühendisliği Bölüm Başkanı sayın Yrd.Doç.DR. Canan YILMAZ hanımefendiye, Erciyes Üniversitesi Bilgisayar Mühendisliği Bölümünden sayın Doç.Dr.Şeref SAĞIROĞLU beyefendiye, Erciyes Üniversitesi Sivil Havacılık Meslek Yüksekokulundan sayın Öğr.Gör.Dr. Mehmet ERLER beyefendiye, Erciyes Üniversitesi İnşaat Mühendisliği Bölümünden Yrd.Doç.Dr. Fatih ALTUN beyefendiye ve Erciyes Üniversitesi İnşaat Mühendisliği Bölümünden Yrd.Doç.Dr. Mehmet ARDIÇLIOĞLU beyefendiye teşekkür ederim.

Çalışmalarına her yönden destek olan Erciyes Üniversitesi Jeodezi ve Fotogrametri Mühendisliği Bölümünden sayın Yrd.Doç.Dr. Erkan BEŞDOK beyefendiye teşekkür ederim.

Çalışmalarım süresince gece-gündüz her zaman sabırla beni destekleyen fedakar eşim sevgili Özlem ÖZKAN hanımefendiye ve aileme çok teşekkür ederim.

KASIM, 2001

Coşkun ÖZKAN

İÇİNDEKİLER

KISALTMALAR	VI
TABLO LİSTESİ	VII
ŞEKİL LİSTESİ	X
SEMBOL LİSTESİ	XIII
ÖZET	XV
SUMMARY	XIX
1. GİRİŞ	1
2. UZAKTAN ALGILAMANIN FİZİKSEL TEMELLERİ	9
2.1. Elektromanyetik Enerji	9
2.2. Elektromanyetik Spektrum	10
2.3. Standart Terimler ve Birimler	12
2.4. Uzaktan Algılamada Spektral Bölgeler	13
2.4.1. Atmosfer Pencereleeri	14
2.5. Optik EMR Modelleri	15
2.5.1. Görünür-Kısa Dalga Kızılötesi Bölge	15
2.5.2. Orta Dalga Kızılötesi - Isıl Kızılötesi Bölge	18
2.6. Cisimlerin Spektral Özellikleri	21
2.6.1. Bitki Örtüsünün Spektral Özellikleri	21
2.6.2. Toprağın Spektral Özellikleri	22
2.6.3. Suyun Spektral Özellikleri	23
3. UZAKTAN ALGILAMA UYDU SİSTEMLERİ	25
3.1. Uzaktan Algılama Sistem Karakteristikleri	26
3.1.1. Uzaysal Çözünürlük	27
3.1.2. Spektral Çözünürlük	29
3.1.3. Radyometrik Çözünürlük	30
3.1.4. Zamansal Çözünürlük	30
3.2. LANDSAT Uydu Sistemi	31
4. DİJİTAL GÖRÜNTÜ VE SINIFLANDIRMA TEKNİKLERİ	33
4.1. Dijital Görüntü	34
4.2. Görüntü Karakteristikleri	36
4.2.1. Histogram ve Kümülatif Histogram	36
4.2.2. İstatistiksel Parametreler	37
4.3. Dijital Görüntü Sınıflandırması	39
4.3.1. Piksel Bazlı Sınıflandırma	41

4.3.2. Alan Bazlı Sınıflandırma	42
4.3.3. Özellik Çıkartımı	43
4.3.4. Eğitim	46
4.3.5. İstatistiksel Sınıflandırıcılar	48
4.3.5.1 Maksimum Olabilirlik Yöntemi	49
4.3.6. Sınıflandırma Doğruluğu	56
4.3.6.1 Genel Doğruluk	56
4.3.6.2 Kappa Doğruluğu	58
5. YAPAY SINIR AĞLARI VE SINIFLANDIRMA TEKNİKLERİ	60
5.1. Tanım ve Özellikler	62
5.2. Biyolojik Sinir Ağı: Beyin	66
5.3. İşlemci Eleman (Yapay Nöron)	68
5.4. Aktivasyon Fonksiyonu	70
5.5. Yapay Sinir Ağlarının Sınıflandırılması	73
5.5.1. YSA'ların Yapılarına Göre Sınıflandırılması	73
5.5.1.1 İleri Beslemeli Ağlar	73
5.5.1.2 Geri Beslemeli Ağlar	73
5.5.2. YSA'ların Öğrenme Algoritmalarına Göre Sınıflandırılması	74
5.5.2.1 Kontrollü Öğrenme	74
5.5.2.2 Kontrolsüz Öğrenme	74
5.5.2.3 Takviyeli Öğrenme	74
5.6. Çok Katmanlı Perseptron	75
5.6.1. Delta Geri Yayılma Öğrenme Algoritması	76
5.6.2. Delta-Bar-Delta Öğrenme Algoritması	82
5.6.3. Genişletilmiş Delta-Bar-Delta Öğrenme Algoritması	85
5.6.4. Esnek Geri Yayılım Öğrenme Algoritması	88
5.6.5. Eşleştirmeli Gradyent (Conjugate Gradient) Öğrenme Algoritmaları	89
5.6.5.1 Fletcher-Reeves Öğrenme Yöntemi	90
5.6.5.2 Polak-Ribiere Öğrenme Yöntemi	91
5.6.5.3 Powell-Beale Öğrenme Yöntemi	92
5.6.6. Ölçeklendirilmiş Eşleştirmeli Gradyent Öğrenme Algoritması	92
5.6.7. Kuasi-Newton Öğrenme Algoritmaları	94
5.6.7.1 BFGS Öğrenme Yöntemi	94
5.6.7.2 Tek Adım Sekant Öğrenme Yöntemi	95
5.7. LVQ (Learning Vector Quantization)	95
5.7.1. LVQ1	97
5.7.2. LVQ2	99
5.8. Radyal Tabanlı Yapay Sinir Ağı Yapısı	100
5.9. YSA ile Görüntü Sınıflandırma	103
5.9.1. Ön İşleme	104
5.9.2. Ağ Girişinin Kodlanması	104
5.9.3. Ağ Çıkışının Kodlanması	106
5.9.4. Sınıfların Çıkarılması	106
5.9.5. Ağ Topolojisi	107
5.9.6. YSA'da Eğitim	109
5.9.7. YSA'da Patern Tanıma ve Karar Sınırları	111
5.10. Uzaktan Algılama ve YSA	112

6. UYGULAMA	122
6.1. Genel Bilgiler	122
6.2. Kullanılan Donanım ve Yazılım Özellikleri	124
6.3. Kullanılan Veri Modeli	125
6.4. Çalışma Alanı	126
6.5. Eğitim ve Test Alanlarının Seçimi	127
6.6. Maksimum Olabilirlik Sınıflandırma Uygulaması	134
6.7. Yapay Sinir Ağları Uygulaması	139
6.7.1. MLP YSA Yapısı Uygulaması	145
6.7.1.1 Delta Öğrenme Algoritması	145
6.7.1.2 Delta-Bar-Delta Öğrenme Algoritması	149
6.7.1.3 Genişletilmiş Delta-Bar-Delta Öğrenme Algoritması	153
6.7.1.4 BFGS Kuasi-Newton Öğrenme Algoritması	156
6.7.1.5 Eşleştirmeli Gradyent Powell-Beale Algoritması	159
6.7.1.6 Eşleştirmeli Gradyent Fletcher-Reeves Algoritması	163
6.7.1.7 Eşleştirmeli Gradyent Polak-Ribiere Algoritması	166
6.7.1.8 Tek Adım Sekant Algoritması	170
6.7.1.9 Esnek Geri Yayılma Öğrenme Algoritması	173
6.7.1.10 Ölçeklendirilmiş Eşleştirmeli Gradyent Algoritması	177
6.7.2. LVQ YSA Yapısı Uygulaması	180
6.7.3. RBF YSA Yapısı Uygulaması	184
6.7.4. Genel Karşılaştırma	188
6.7.5. Sürekli Eğitim	191
7. SONUÇLAR	196
KAYNAKLAR	204
ÖZGEÇMİŞ	224

KISALTMALAR

EMR	: Elektromanyetik enerji (Electromagnetic Radiation).
MO	: Maksimum olabilirlik sınıflandırma yöntemi.
ISODATA	: Iterative Self Organizing Data kontrolsüz sınıflandırma algoritması.
TM	: Tematik haritalayıcı (Thematic Mapper).
MSS	: Çok spektrumlu tarayıcı (Multi-Spectral scanner).
DN	: Piksel parlaklık seviyesi (Digital Number).
YSA	: Yapay sinir ağı.
MLP	: Çok katmanlı perseptron (Multi-Layer Perseptron).
BFGS	: Broyden-Fletcher-Goldfarb-Shanno öğrenme algoritması.
EGPB	: Eşleştirmeli gradiyent Powell-Beale öğrenme algoritması.
EGFR	: Eşleştirmeli gradiyent Fletcher-Rieves öğrenme algoritması.
EGPR	: Eşleştirmeli gradiyent Polak-Ribiere öğrenme algoritması.
TAS	: Tek adım sekant öğrenme algoritması.
EG	: Esnek geri yayılma öğrenme algoritması.
ÖEG	: Ölçeklendirilmiş eşleştirmeli gradiyent öğrenme algoritması.
DBD	: Delta-Bar-Delta öğrenme algoritması.
EDBD	: Genişletilmiş (Extended) Delta-Bar-Delta öğrenme algoritması.
LVQ	: Learning Vector Quantization.
RBF	: Radial Basis Function.
GD	: Sınıflandırma genel doğruluk değeri.
ÜD	: Sınıflandırma üretici doğruluk değeri.
KD	: Sınıflandırma kullanıcı doğruluk değeri.
KaD	: Kappa istatistiği doğruluğu.
OYF	: Olasılık yoğunluk fonksiyonu.
V	: Görünür bölge (Visible).
NIR	: Kızılötesi bölge (Near Infrared).
SWIR	: Kısa dalga kızılötesi bölge (Shortwave Infrared).
TIR	: Termal (ısı) kızılötesi bölge (Thermal Infrared).
GSi	: Yeryüzü örnekleme aralığı (Ground Sample Interval).
FOV	: Görüş alanı (Field of View).
IFOV	: Anlık görüş alanı (Instantaneous Field of View).
GIFOV	: Yeryüzü anlık görüş alanı (Ground Instantaneous Field of View).
PSF	: Noktasal yayılım fonksiyonu (Point Spread Function).
GCP	: Yer kontrol noktası (Ground Control Point).
BR	: İki boyutlu yansıtım (Bidirectional Reflectance).
LAI	: Yaprak alanı indeksi (Leaf Area Index).
GU	: Genel uygunluk değeri.
WTA	: Kazanan Hepsini Alır yöntemi (Winner Takes All).

TABLO LİSTESİ

Tablo 2.1: Radyometrik birimler.	12
Tablo 2.2: Oransal radyometrik terimler.	13
Tablo 2.3: Uzaktan algılamada kullanılan başlıca spektral bölgeler.	14
Tablo 2.4: Atmosfer pencereleri.	14
Tablo 3.1: LANDSAT 1-5 uyduları ve algılayıcı sistem özellikleri.....	32
Tablo 3.2: LANDSAT 7 uydusu algılayıcı sistem özellikleri.....	32
Tablo 5.1: İstatistik ve YSA arasındaki benzer yönler.	62
Tablo 5.2: Biyolojik sinir sistemi ve YSA sistemi arasındaki benzerlikler.	69
Tablo 5.3: Aktivasyon fonksiyonlarının matematiksel yapıları.....	72
Tablo 6.1: Sınıf özellikleri.	127
Tablo 6.2: Eğitim piksellerinin istatistiksel özellikleri.	128
Tablo 6.3: Test piksellerinin istatistiksel özellikleri.	128
Tablo 6.4: Diverjans değerleri.	134
Tablo 6.5: Dönüştürülmüş diverjans değerleri.....	134
Tablo 6.6: MO yöntemine göre eğitim verisi hata matrisi (GD=% 94.1 ve Kappa=% 93.4).	137
Tablo 6.7: MO yöntemine göre test verisi hata matrisi (GD=% 84.9 ve Kappa=83.0).	138
Tablo 6.8: MLP YSA yapısı öğrenme algoritmalarında kullanılan aktivasyon fonksiyonları.	140
Tablo 6.9: YSA çıkışının veri yapısı.....	142
Tablo 6.10: MLP yapılarının mimari özellikleri.....	142
Tablo 6.11: RBF yapılarının mimari özellikleri.	143
Tablo 6.12: LVQ yapılarının mimari özellikleri.....	143
Tablo 6.13: MLP yapılarının eğitiminde elde edilen epoklar.	145
Tablo 6.14: LANDSATM kanal korelasyon değerleri.	145
Tablo 6.15: Delta algoritması ile elde edilen GD, Kappa ve MSE değerleri.....	146
Tablo 6.16: Delta 4 nolu yapının test verisi hata matrisi (GD=%90.0, Kappa=%88.7).	147
Tablo 6.17: Delta yapılarının test verisi üretici doğruluk değerleri.....	148
Tablo 6.18: Delta 4 nolu yapı ve MO çapraz sınıflandırma matrisi (GU=%68). ...	149
Tablo 6.19: Delta yapılarının kendi içinde ve MO yöntemiyle olan uygunluk matrisi.	149
Tablo 6.20: DBD algoritması ile elde edilen GD, Kappa ve MSE değerleri.....	149
Tablo 6.21: DBD 1 nolu yapının test verisi hata matrisi (GD=%91.1, Kappa=%90.0).	151
Tablo 6.22: DBD yapılarının test verisi üretici doğruluk değerleri.	152
Tablo 6.23: DBD 1 nolu yapı ve MO çapraz sınıflandırma matrisi (GU=%68.7)..	152
Tablo 6.24: DBD yapılarının kendi içinde ve MO yöntemiyle olan uygunluk matrisi.	152
Tablo 6.25: EDBD algoritması ile elde edilen GD, Kappa ve MSE değerleri	153

Tablo 6.26: EDBD 3 nolu yapının test verisi hata matrisi (GD=%90.3, Kappa=%89.1).	154
Tablo 6.27: EDBD yapılarının test verisi sınıflandırma üretici doğruluk değerleri.	155
Tablo 6.28: EDBD 3 nolu yapı ve MO çapraz sınıflandırma matrisi (GU=%67.7).	156
Tablo 6.29: EDBD yapılarının kendi içinde ve MO yöntemiyle olan uygunluk matrisi.	156
Tablo 6.30: BFGS algoritması ile elde edilen GD, Kappa ve MSE değerleri	156
Tablo 6.31: BFGS 9 nolu yapının test verisi hata matrisi (GD=%90.5, Kappa=%89.3).	157
Tablo 6.32: BFGS yapılarının test verisi üretici doğruluk değerleri.	158
Tablo 6.33: BFGS 9 nolu yapı ve MO çapraz sınıflandırma matrisi (GU=%67.4).	159
Tablo 6.34: BFGS yapılarının kendi içinde ve MO yöntemiyle olan uygunluk matrisi.	159
Tablo 6.35: EGPB algoritması ile elde edilen GD, Kappa ve MSE değerleri.	160
Tablo 6.36: EGPB 6 nolu yapının test verisi hata matrisi (GD=%90.8, Kappa=%89.6).	161
Tablo 6.37: EGPB yapılarının test verisi üretici doğruluk değerleri.	162
Tablo 6.38: EGPB 6 nolu yapı ve MO çapraz sınıflandırma matrisi (GU=%67.5).	163
Tablo 6.39: EGPB yapılarının kendi içinde ve MO yöntemiyle olan uygunluk matrisi.	163
Tablo 6.40: EGFR algoritması ile elde edilen GD, Kappa ve MSE değerleri	163
Tablo 6.41: EGFR 2 nolu yapının test verisi hata matrisi (GD=%90.5, Kappa=%89.2).	164
Tablo 6.42: EGFR yapılarının test verisi üretici doğruluk değerleri.	165
Tablo 6.43: EGFR 2 nolu yapı ve MO çapraz sınıflandırma matrisi (GU=%59.1).	166
Tablo 6.44: EGFR yapılarının kendi içinde ve MO yöntemiyle olan uygunluk matrisi.	166
Tablo 6.45: EGPR algoritması ile elde edilen GD, Kappa ve MSE değerleri	167
Tablo 6.46: EGPR 7 nolu yapının test verisi hata matrisi (GD=%90.4, Kappa=%89.2).	168
Tablo 6.47: EGPR yapılarının test verisi üretici doğruluk değerleri.	169
Tablo 6.48: EGPR 7 nolu yapı ve MO çapraz sınıflandırma matrisi (GU=%65.7).	170
Tablo 6.49: EGPR yapılarının kendi içinde ve MO yöntemiyle olan uygunluk matrisi.	170
Tablo 6.50: TAS algoritması ile elde edilen GD, Kappa ve MSE değerleri	170
Tablo 6.51: TAS 7 nolu yapının test verisi hata matrisi (GD=%90.8, Kappa=%89.6).	171
Tablo 6.52: TAS yapılarının test verisi üretici doğruluk değerleri.	172
Tablo 6.53: TAS 7 nolu yapı ve MO çapraz sınıflandırma matrisi (GU=%66.6).	173
Tablo 6.54: TAS yapılarının kendi içinde ve MO yöntemiyle olan uygunluk matrisi.	173
Tablo 6.55: EG algoritması ile elde edilen GD, Kappa ve MSE değerleri	174
Tablo 6.56: EG 9 nolu yapının test verisi hata matrisi (GD=%91.4, Kappa=%90.3).	175
Tablo 6.57: EG yapılarının test verisi üretici doğruluk değerleri.	176
Tablo 6.58: EG 9 nolu yapı ve MO çapraz sınıflandırma matrisi (GU=%65).	177
Tablo 6.59: EG yapılarının kendi içinde ve MO yöntemiyle olan uygunluk matrisi.	177

Tablo 6.60: ÖEG algoritması ile elde edilen GD, Kappa ve MSE değerleri	177
Tablo 6.61: ÖEG 9 nolu yapının test verisi hata matrisi (GD=%90.3, Kappa=%89.1).	178
Tablo 6.62: ÖEG yapılarının test verisi üretici doğruluk değerleri.	179
Tablo 6.63: ÖEG 9 nolu yapı ve MO çapraz sınıflandırma matrisi (GU=%66.1)..	180
Tablo 6.64: ÖEG yapılarının kendi içinde ve MO yöntemiyle olan uygunluk matrisi.	180
Tablo 6.65: LVQ YSA mimari yapısıyla elde edilen GD, Kappa ve MSE değerleri	182
Tablo 6.66: LVQ 3 nolu yapı test verisi hata matrisi (GD=89.8, Kappa=88.5).	182
Tablo 6.67: LVQ yapılarına ait üretici sınıflandırma doğruluk değerleri.....	184
Tablo 6.68: LVQ 3 nolu yapı ve MO çapraz sınıflandırma matrisi (GU=%59.5)..	184
Tablo 6.69: BRK YSA mimari yapısıyla elde edilen GD, Kappa ve MSE değerleri.	185
Tablo 6.70: RBF 3 nolu yapının test verisi hata matrisi (GD=%88.4, Kappa=%86.9).	186
Tablo 6.71: RBF yapılarının test verisi üretici doğruluk değerleri.	187
Tablo 6.72: RBF 3 nolu yapı ve MO çapraz sınıflandırma matrisi (GU=%65.8). .	188
Tablo 6.73: RBF yapılarının kendi içinde ve MO yöntemiyle olan uygunluk matrisi.	188
Tablo 6.74: Bütün sınıflandırma algoritmaları için test verisi GD, Kappa ve üretici doğruluk değerleri.....	188
Tablo 6.75: MLP öğrenme algoritmalarının sürekli ve kesintili eğitim performansları.	192
Tablo 6.76: Sürekli ve kesintili eğitilen yapıların üretici doğruluk değerleri.....	192

ŞEKİL LİSTESİ

Şekil 1.1: Uzaktan algılama platformu olarak güvercinlerin kullanımı.	1
Şekil 1.2: Uzaktan algılama modeli.	2
Şekil 1.3: Özellik uzayının karar sınırlarıyla bölünerek sınıflandırma işleminin gerçekleştirilmesi.	5
Şekil 2.1: Elektromanyetik enerjinin dalga karakteri.	10
Şekil 2.2: Elektromanyetik spektrum	11
Şekil 2.3: Uydu bakış açısına göre atmosferik yol geçirimi.	15
Şekil 2.4: Yüzeydeki bir hava kütesinden geçen güneş kaynaklı EMR'nin yeryüzündeki spektral birim ışınlılığı.	16
Şekil 2.5: Solar yansıtım bölgesindeki ışıma bileşenleri.	17
Şekil 2.6: Güneş ve yer yüzeyi sıcaklıklarında siyah cisim ışınlımı.	19
Şekil 2.7: Atmosferin orta ve ısı kızıltötesi bölgedeki geçirimsizliği.	20
Şekil 3.1: Elektro-optik uzaktan algılama sisteminin ana bileşenleri.	25
Şekil 3.2: Dijital uydu görüntü verisinin (x,y,λ) boyutlarında görselleştirilmesi.	26
Şekil 3.3: Optik bir sensördeki tek bir detektörün basitleştirilmiş geometrisi.	28
Şekil 3.4: LANDSAT uydu sistemlerinin kullanım zamanları.	31
Şekil 4.1: Dijital görüntü koordinat sistemi (satır-sütun).	34
Şekil 4.2: (a) Kare yapıli grid, (b) altıgen grid.	35
Şekil 4.3: Özellik uzayında oluşan karar sınırları içinde eğitim verisi için olası iki durum.	42
Şekil 4.4: Alt piksel ve piksel sınıflandırma işlemleri arasındaki fark.	42
Şekil 4.5: Dört farklı yeryüzü cismine ait Gauss olasılık yoğunluk fonksiyonu eğri yüzeyleri.	50
Şekil 4.6: Dört farklı yeryüzü cisminin Gauss olasılık yoğunluk fonksiyonu eş olasılık eğrileri.	50
Şekil 4.7: İki sınıfa ait olasılık yoğunluk fonksiyonları.	54
Şekil 4.8: Hata matrisi.	57
Şekil 5.1: Biyolojik sinir hücresinin (nöron) yapısı.	68
Şekil 5.2: Bias olmaksızın tek girişli işlemci eleman modeli.	69
Şekil 5.3: Bias parametresiyle tek girişli işlemci eleman modeli.	70
Şekil 5.4: Bias elemanı ile beraber çok girişli işlemci eleman modeli.	70
Şekil 5.5: Aktivasyon fonksiyonları; (i) sigmoid, (ii) tanjant hiperbolik, (iii) lineer, (iv) keskin sınırlayıcı, (v) Gauss, (vi) çoklu-kuadratik.	72
Şekil 5.6: Çok katmanlı perseptron ağı yapısı.	75
Şekil 5.7: Geri-yayılım akış şeması.	81
Şekil 5.8: LVQ YSA mimari yapısı.	96
Şekil 5.9: RBF YSA yapısının ara katman işlemci eleman (patern birimi) yapısı.	100
Şekil 5.10: RBF YSA mimari yapısı.	101
Şekil 5.11: Üç ayrı bölgeye düşen veri noktaları. Bu sınıfları ayırmak için (a) hiper-yüzeyler, (b) her bir sınıfa bir kernel fonksiyonu yerleştirilir.	102
Şekil 5.12: YSA'da örnek giriş kodlaması.	104
Şekil 5.13: Patern tanımda YSA ara katmanlarının etkisi.	112

Şekil 5.14: Hiyerarşik YSA yapısı.	115
Şekil 5.15: Entegre sınıflandırma işlemi.	119
Şekil 6.1: Çalışma alanı (LANDSAT TM, RGB: 3/2/1 doğal renkli uydu görüntüsü) ve eğitim alanları.	126
Şekil 6.2: İki boyutlu özellik uzayları ve alıştırma paternlerinin bu uzaylardaki dağılımları.	130
Şekil 6.3: İki boyutlu özellik uzayları ve alıştırma paternlerinin bu uzaylardaki dağılımları.	131
Şekil 6.4: Sınıf alıştırma verilerinin iki boyutlu özellik uzayındaki logaritmik Normal olasılık yoğunluk dağılımları.	132
Şekil 6.5: Sınıf alıştırma verilerinin iki boyutlu özellik uzayındaki logaritmik Normal olasılık yoğunluk dağılımları.	133
Şekil 6.6: Renk lejantı.	137
Şekil 6.7: Maksimum Olabilirlik yönteminden elde edilen sınıflandırılmış görüntü.	137
Şekil 6.8: Maksimum Olabilirlik yönteminin ürettiği karar sınırları.	139
Şekil 6.9: YSA ile sınıflandırmada hesap akış şeması.	141
Şekil 6.10: Delta kuralıyla 4 nolu MLP yapısında; (a) GD-Epok ve (b) MSE-Epok grafikleri.	146
Şekil 6.12: Delta öğrenme kuralının oluşturduğu karar bölgeleri.	148
Şekil 6.14: DBD kuralıyla 1 nolu MLP yapısında; (a) GD-Epok ve (b) MSE-Epok grafiği.	150
Şekil 6.15: DBD öğrenme kuralının oluşturduğu karar uzayları.	151
Şekil 6.16: EDBD kuralıyla 3 nolu MLP yapısında; (a) GD-Epok ve (b) MSE-Epok grafiği.	153
Şekil 6.17: EDBD öğrenme kuralının oluşturduğu karar bölgeleri.	155
Şekil 6.18: BFGS kuralıyla 9 nolu MLP yapısında; (a) GD-Epok ve (b) MSE-Epok grafiği.	157
Şekil 6.19: BFGS öğrenme kuralının ürettiği karar bölgeleri.	158
Şekil 6.20: EGPB kuralıyla 6 nolu MLP yapısında; (a) GD-Epok ve (b) MSE-Epok grafiği.	160
Şekil 6.21: EGPB öğrenme kuralının ürettiği karar bölgeleri.	162
Şekil 6.22: EGFR kuralıyla 2 nolu MLP yapısında; (a) GD-Epok ve (b) MSE-Epok grafiği.	164
Şekil 6.23: EGFR öğrenme kuralının ürettiği karar bölgeleri.	165
Şekil 6.24: EGPR kuralıyla 7 nolu MLP yapısında; (a) GD-Epok ve (b) MSE-Epok grafiği.	167
Şekil 6.25: EGPR öğrenme kuralının ürettiği karar bölgeleri.	169
Şekil 6.26: TAS kuralıyla 7 nolu MLP yapısında; (a) GD-Epok ve (b) MSE-Epok grafiği.	171
Şekil 6.27: TAS öğrenme kuralının ürettiği karar bölgeleri.	172
Şekil 6.28: EG kuralıyla 9 nolu MLP yapısında; (a) GD-Epok ve (b) MSE-Epok grafiği.	174
Şekil 6.29: EG öğrenme kuralının ürettiği karar bölgeleri.	176
Şekil 6.30: ÖEG kuralıyla 9 nolu MLP yapısında; (a) GD-Epok ve (b) MSE-Epok grafiği.	178
Şekil 6.31: ÖEG öğrenme kuralının ürettiği karar bölgeleri.	179
Şekil 6.32: Eğitim ve test verisi sınıflandırma doğruluklarının ara katman işlemci eleman sayısı ile olan gösterimi.	181

Şekil 6.33: Eğitim ve test verisi MSE değerlerinin ara katman işlemci eleman sayısıyla olan gösterimi.	181
Şekil 6.34: LVQ yapısının ürettiği karar bölgeleri.....	183
Şekil 6.35: RBF YSA yapısında 3 nolu yapıda; (a) GD-Epok ve (b) MSE-Epok grafiği.	185
Şekil 6.36: RBF yapısının ürettiği karar bölgeleri.	187
Şekil 6.37: Sınıflandırılmış görüntüler: (a) Delta, (b) DBD, (c) EDBD, (d) BFGS, (e) EGPB, (f) EGFR.....	189
Şekil 6.38: Sınıflandırılmış görüntüler: (a) EGPR, (b) TAS, (c) EG, (d) ÖEG, (e) LVQ, (f) RBF.	190
Şekil 6.39: BFGS öğrenme kuralı.	193
Şekil 6.40: EGPB öğrenme kuralı.	193
Şekil 6.41: EGFR öğrenme kuralı.	194
Şekil 6.40: EGPR öğrenme kuralı.	194
Şekil 6.43: TAS öğrenme kuralı.....	194
Şekil 6.44: EG öğrenme kuralı.	195
Şekil 6.45: ÖEG öğrenme kuralı.	195



SEMBOL LİSTESİ

c	: Işık hızı, merkez değer vektörü.
v	: Frekans.
h	: Plack sabiti.
$f(x,y)$	: Görüntü fonksiyonu.
Q	: Işıyan enerji.
ϕ	: Işınır akı.
M	: Işınır çıkış.
E	: Birim ışınlılık.
L	: Işınırılık.
ε	: Yayım.
τ	: Geçirim.
f	: Odak uzaklığı, aktivasyon fonksiyonu.
C	: Kovaryans matrisi.
ρ	: Korelasyon katsayısı, yansıtım.
R	: Korelasyon matrisi.
H	: Entropi, algılayıcı yüksekliği.
m	: Moment.
J	: Diverjans uzaklığı.
TJ	: Dönüştürülmüş diverjans uzaklığı.
B	: Bhattacharyya uzaklığı.
L	: Sınıflandırma hatası (kayıp) fonksiyonu.
$r(x)$	: x paterni için ortalama kayıp fonksiyonu.
$d(x)$	: x paterni için Bayes karar fonksiyonu.
n_{i+}	: i kategorisine atanan sınıflandırma verisi piksel sayısı.
n_{+j}	: j kategorisine atanan referans verisi piksel sayısı.
α	: Standart sapma, öğrenme oranı, 1. çekme parametresi, yutulmuş.
μ	: Ortalama değer, momentum oranı, cezalandırma oranı.
U	: Ortalama değer vektörü.
E	: Hata değeri.
t	: YSA giriş vektörü.
o	: YSA çıkış vektörü.
d	: YSA hedef çıkış vektörü.
w	: Bağlantı ağırlığı, algılayıcı detektör genişliği.
Δw	: Ağırlık değişimi.
$\Delta \alpha$	: Öğrenme oranı değişimi.
δ	: Ağırlık değişiminin gradiyent bileşeni.
$\bar{\delta}$	: Önceki gradiyent bileşeninin ağırlıklı ve üstel ortalaması.
θ	: Konveks ağırlıklandırma faktörü.
κ	: Sabit öğrenme oranı artımı.
ϕ	: Sabit öğrenme oranı azaltımı.
$\Delta \mu$	: Bağlantı momentum değişim oranı.

κ_α	: Sabit öğrenme oranı ölçek faktörü.
κ_μ	: Sabit momentum oranı ölçek faktörü.
γ_α	: Sabit öğrenme oranı üstel faktörü.
γ_μ	: Sabit momentum oranı üstel fonksiyonu.
ϕ_α	: Sabit öğrenme oranı azaltım faktörü.
ϕ_μ	: Sabit momentum oranı azaltım faktörü.
$\alpha_{\max}$	: Öğrenme oranındaki üst sınır.
$\mu_{\max}$	: Momentum oranındaki üst sınır.
λ	: Düzeltme tolerans faktörü, ölçekleme faktörü, dalga boyu.
Δ	: Güncelleme değeri.
η^+	: Ağırlık değişimi artırma faktörü.
η^-	: Ağırlık değişimi azaltma faktörü.
$\mathbf{p}$	: Arama vektörü.
$\mathbf{A}$	: Hessian matrisi.
β	: 2. çekme parametresi.
γ	: İtme oranı.
φ	: Tahmini frekans.
ω	: LVQ2 algoritması genişlik parametresi.



UYDU GÖRÜNTÜ VERİSİNİN YAPAY SİNİR AĞLARI İLE SINIFLANDIRILMASI

ÖZET

Uzaktan algılanmış uydu görüntü verilerini kullanan bir çok farklı disiplin için bu verilerden elde edilecek tematik bilgiler önemlidir. İhtiyaç duyulan bu tematik bilgiler, çok spektrumlu orijinal uydu görüntü verilerinin, renk veya doku ile hedef kategorilerini temsil eden kodlanmış tematik haritalara indirgenmesiyle elde edilir. Sınıflandırma olarak adlandırılan bu işlem çıkarılacak kategorileri temsil eden örnekleme alanlarının kullanılmasıyla kontrollü bir şekilde gerçekleştirilebilir. Bir çok disiplin tarafından uzaktan algılamanın sonuç ürünü olarak istenen bu 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 zeki 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 teknikleri literatürde çok spektrumlu uydu görüntü verilerinin sınıflandırılması için üzerinde en çok araştırmanın yapıldığı alan olmuştur. Dağılımdan bağımsız, hataları ve gürültüyü tolere edebilen, değişen çevre şartlarına kendini uyarlayabilen, öğrenme ve genelleme yeteneğine sahip karakterinden dolayı bir çok bilimsel alanda olduğu gibi uzaktan algılama biliminde de YSA'nın etkin kullanım alanları araştırılmaktadır.

Bu çalışmada çok spektrumlu LANDSAT TM görüntü verisinin sınıflandırılması için hem klasik Maksimum Olabilirlik yöntemi ile farklı YSA sınıflandırma algoritmalarının karşılaştırılması, hem de kullanılan bu YSA sınıflandırma algoritmalarının kendi aralarında karşılaştırılması amaçlanmıştır. Ayrıca farklı YSA yapıları için optimum ağ topolojisinin ve Çok Katmanlı Perseptron (MLP) YSA yapısı için optimum öğrenme algoritmasının belirlenmesi amaçlanmıştır.

Bu amaçlar için LANDSAT TM uydu sistemine ait İstanbul ili İkitelli bölgesi civarını kapsayan uzaktan algılanmış görüntü verisi çalışma verisi olarak seçilmiştir. Uzaktan algılanmış görüntü verisinin sahip olduğu 7 spektral kanaldan, ısı kanal olan 6. kanal dışındaki diğer 6 kanal belirtilen amaçların gerçekleştirilmesi için kullanılmıştır. Gerçekleştirilen sınıflandırma uygulamalarında çalışma verisi piksel tabanlı olarak ele alınmıştır.

Kontrollü sınıflandırma işleminin en kritik aşaması olan eğitim alanlarının seçimi için görüntünün ISODATA kontrolsüz sınıflandırma algoritmasından elde edilen

sınıflandırma görüntüsü ile bütün bölgeyi kapsayan 1/5000 ölçekli fotogrametrik hava fotoğraflarından yararlanılmıştır. Yapılan bu analizlerle belirlenen toplam 12 arazi sınıfı Matlab platformunda yazılan bir kod aracılığıyla poligon vektörler kullanılarak seçilmiştir. Bu kod elde edilen eğitim alanlarını hem Maksimum Olabilirlik hem de YSA sınıflandırma algoritmalarında kullanılabilecek bir formatta üretmiştir.

Oluşturulan eğitim bölgelerinin ayırt edilebilirlik analizleri, dönüştürülmüş diverjans değerlerinin hesaplanmasıyla kantitatif olarak yapıldığı gibi bütün ikili alt kanal kombinasyonlarının oluşturduğu iki boyutlu saçılım grafikleri üzerine sınıf yoğunlukları, sınıfların ortalama değerleri etrafında standart sapma değerlerine göre konumlandırılarak grafik olarak da yapılmıştır. Ayrıca 3. ve 4. kanalların oluşturduğu iki boyutlu özellik uzayı üzerinde sınıflara ait logaritmik Gauss olasılık yoğunluk fonksiyonları da birbirlerine göre derecelendirilerek hazırlanmıştır. Bu grafikler üzerinde de sınıfların dağılımları birbirlerine göre incelenmiştir.

Literatüre uygun olarak, eğitim bölgelerinin seçildiği aynı bölgelerden fakat eğitim verilerini içermeyen test verileri seçilmiştir. Test verilerinin oluşturulmasındaki amaç, herhangi bir sınıflandırma algoritmasının elde edeceği sınıflandırma performansını istatistiksel olarak yansız değerlendirmek ve böylece bu sınıflandırma algoritmasının eğitim verisinden yararlanarak elde ettiği analitik sınıflandırma yeteneğinin ne kadar genel olduğunu objektif olarak ortaya koymaktır.

Eğitim ve test verilerinin hazırlanmasından sonra ilk uygulama olarak Maksimum Olabilirlik (MO) sınıflandırma yöntemi Matlab platformunda literatüre uygun olarak yazılan program kodu ile gerçekleştirilmiştir.

YSA uygulaması kapsamında, literatürde çok spektrumlu uzaktan algılanmış görüntü verilerinin sınıflandırılması için kullanılmış olan 3 farklı YSA yapısı uygulanmıştır. Bu yapılar aşağıda verilmiştir:

- 1- MLP (Çok Katmanlı Perseptron)
- 2- LVQ (Learning Vector Quantization)
- 3- RBF (Radial Basis Function)

Yine literatürde MLP öğrenme algoritmaları içinde çok spektrumlu uydu görüntü verilerinin sınıflandırılması için çok sık kullanılmış standart geri yayılma (Delta) öğrenme algoritmasına ek olarak 9 farklı MLP öğrenme algoritması ile birlikte toplam 10 öğrenme algoritması ele alınmıştır. MLP YSA yapıları için kullanılan geri yayılma öğrenme algoritmaları;

- 1- Delta
- 2- Delta-Bar-Delta (DBD)
- 3- Genişletilmiş Delta-Bar-Delta (EDBD)
- 4- BFGS Kuasi-Newton (BFGS)
- 5- Eşleştirmeli Gardiyent Powell-Beale (EGPB)

- 6- Eşleştirmeli Gradyent Fletcher-Reeves (EGFR)
- 7- Eşleştirmeli Gradyent Polak-Ribiere (EGPR)
- 8- Tek Adım Sekant Kuasi-Newton (TAS)
- 9- Esnek Geri Yayılma (EG)
- 10- Ölçeklendirilmiş Eşleştirmeli Gradyent (ÖEG)

olarak belirlenmiştir.

YSA giriş verisi, kullanılan 6 kanal (TM 1, 2, 3, 4, 5 ve 7. kanallar) için oluşturulmuştur. YSA giriş katmanı, görüntü giriş verisindeki her bir kanalı bir işlemci eleman temsil edecek şekilde toplam 6 işlemci elemandan oluşurken çıkış katmanı ise her bir sınıfı bir işlemci eleman temsil edecek şekilde toplam 12 işlemci elemandan oluşmuştur.

Bütün YSA algoritmaları için görüntü giriş verisi ağın yakınsama hızını ve kabiliyetini artırmak amacı ile YSA içindeki işlemsel ölçeğe uygun olarak $[-1 +1]$ kapalı aralığına lineer olarak ölçeklenmiştir. Ağ çıkış verileri de ait olduğu sınıf için 1 ve ait olmadığı diğer sınıflar için 0 değerini alacak şekilde hazırlanmıştır.

Bütün MLP öğrenme algoritmaları için 9 farklı ağ topolojisi uygulanmıştır. Tek ara katmanlı ağların ara katmanlarında 12, 15, 18, 24 ve 30 işlemci eleman kullanılırken, iki ara katmanlı ağların 1. ve 2. ara katmanlarında sırasıyla 9-15, 12-24, 18-24 ve 24-30 işlemci eleman kullanılmıştır.

Delta, DBD ve EDBD öğrenme algoritmalarının çıkış katmanlarında “softmax” aktivasyon fonksiyonu kullanılırken, diğer öğrenme algoritmalarının çıkış katmanlarında tanjant hiperbolik (TANH) aktivasyon fonksiyonu kullanılmıştır. Ara katmanlarında sigmoid aktivasyon fonksiyonunun kullanıldığı EDBD algoritması dışındaki diğer tüm MLP öğrenme algoritmaları için ara katmanlarda TANH aktivasyon fonksiyonu kullanılmıştır.

LVQ YSA yapısı uygulamasında, bu yapının sahip olduğu dezavantajları ortadan kaldıran LVQ1 ve LVQ2 mekanizmaları birlikte kullanılmıştır. Ağ topolojisi belirlenirken KOHONEN ara katmanı için kullanılan işlemci eleman sayısı üretilen sınıf sayısının 1’den 24’e kadar olan sayılarla çarpılmasıyla belirlenmiştir. Bu şekilde her bir sınıf için kullanılacak referans vektörü sayısı 1’den 24’e kadar geniş bir aralıkta göz önüne alınmıştır.

RBF YSA yapısında ağ topolojileri PROTO ara katmanında 50, 100 ve 200 işlemci eleman kullanılarak belirlenmiştir. Ayrıca değiştirilmiş RBF yapısı için PROTO katmanında 50 ve MLP karakterli 2. ara katmanda 18 işlemci eleman kullanılmıştır.

RBF YSA yapısının PROTO katmanında radyal karakterli Gauss fonksiyonu kullanılırken, çıkış katmanında TANH fonksiyonu kullanılmıştır. Değiştirilmiş RBF yapısının ikinci ara katmanında da TANH fonksiyonu kullanılmıştır.

YSA’nın eğitim sırasında örnek veriyi ezberleyerek genelleme kaybına uğramasını önlemek için her 100 epokta ağ durdurulmuştur. Bu şekilde oluşturulan her bir

istasyon noktasında eğitim ve test verileri için sınıflandırma genel doğruluk (GD), Kappa ve karesel ortalama hata (MSE) değerleri hesaplanmıştır.

İncelenen sınıflandırma problemi için en optimal epok, ağın test verisi GD değerine göre belirlenmiştir. Ağın test verisi için maksimum GD değerini verdiği epoktaki ağ yapısı en optimum ağ yapısı olarak değerlendirilmiştir. Ağı diğer yapılara ve Maksimum Olabilirlik yöntemine karşı temsil eden performans kriterleri (GD, Kappa ve MSE) bu epoktaki ağ yapısı kullanılarak hesaplanmıştır.

Maksimum Olabilirlik ve YSA sınıflandırma yöntemlerinin özellik uzayındaki sınıflandırma karakteristiklerini grafik olarak incelemek için 6 boyutlu orijinal özellik uzayı 2 boyuta indirgenmiştir. Bu amaçla bitki örtüsü ayrımının daha iyi olduğu ve korelasyon değeri diğer kanal kombinasyonlarına göre oldukça düşük olan, görüntünün 3. ve 4. kanalları seçilmiştir. Bu kanalların oluşturduğu iki boyutlu örnek özellik uzayı için bütün sınıflandırma algoritmaları yeniden düzenlenmiştir. Bütün YSA yapıları ve öğrenme algoritmaları giriş katmanında 2, ara katmanında 18 ve çıkış katmanında 12 işlemci eleman bulunacak şekilde tekrar düzenlenmiştir.

Bu uygulamada da en optimum ağ yapısı maksimum test verisi GD değerini üreten epoktaki ağ yapısı olarak seçilmiştir. Bu ağ yapılarının ürettiği karar bölgeleri incelenerek algoritmaların sınıflandırmadaki analitik davranış karakteristikleri anlaşılmaya çalışılmıştır.

Ayrıca elde edilen bütün sınıflandırma sonuç görüntüleri, mevcut 1/5000 ölçekli fotogrametrik hava fotoğraflarıyla karşılaştırılarak, farklı sınıflandırma yöntemlerinden elde edilen sınıflandırma sonuçlarının arazi doğrulukları, eğitim ve test verisi dışında görüntünün bütününde de görsel olarak yapılmıştır.

Son olarak MLP öğrenme algoritmalarından BFGS, EGPB, EGFR, EGPR, TAS, EG ve ÖEG algoritmaları için sürekli ve kesintili eğitimin etkisi incelenmiştir.

CLASSIFICATION OF SATELLITE IMAGERY DATA WITH ARTIFICIAL NEURAL NETWORKS

SUMMARY

The thematic information extracted from the remote sensing data is the end product needed by many different scientific branches that use the remote sensing data. These thematic information is obtained by reducing the spectral data into the colour coded or texture coded maps. This process, which is called as classification, can be done as supervised by using the train data that represents each class. Many researches have been done many studies lately to develop new classification methods for production of these 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 techniques are the most common and basic method which the most researches have been applied to classification problems in literature. Because of its distribution free nature that can tolerate the error and noise, can be adaptive against the changing environmental conditions and can learn and generalise, as in many disciplines, the effective application areas have been investigated in remote sensing, as well.

In this study for classification of multispectral LANDSAT TM imagery, it was aimed to compare both classification abilities of different ANN classification algorithms with the standard maximum likelihood method and classification performances of these ANN classification algorithms among each other. In addition, it was also aimed to determine the optimum net topology and backpropagation learning algorithm.

For these purposes, multispectral LANDSAT TM imagery consists of about İkitelli region of Istanbul province was selected as working data. Among the 7 spectral channels of TM imagery, the 6 channels remaining except thermal 6th channel were used to realize the purposes declared above. In the classification applications, the working data was considered as pixel-based.

In the selection of the training areas which is the most critic phase of classification procedure, the classification result of ISODATA clustering algorithm and 1/5000 scaled photogrammetric aerial photographs were used together. By these analysis, total 12 classes determined were selected with the polygon vectors through a program coded in Matlab. This cod generated the training areas in a format available for both maximum Likelihood and ANN techniques.

As the discrimination analysis of training areas done quantitatively by calculating the transformed divergence values, the graphical analysis were done by positioning the classes according to their standard deviation values around the mean values onto the two dimensional scatter diagrams of all possible sub-channels. In addition, the graphics of the logarithmic Gauss probability density functions of classes were prepared shading relatively to each other. These graphics were examined relatively in terms of the distributions of the classes.

According to the literature, test data which did not consist of the same patterns from the same regions were selected being parallel to the training areas selection. The aim of the test data is to obtain the classification performance of any algorithm as unbiased and thus to show the generalisation skill of this classification technique gathered analytically from the training data objectively.

After the selection of training and test data, firstly Maximum Likelihood classification algorithm was applied. For this, a program written in Matlab program was used.

In the application of ANN classification, the 3 ANN structures that were used in literature for classification of multispectral satellite data were selected. These ANN structures used in this study are as follows:

- 1- MLP (Multi Layer Perceptron)
- 2- LVQ (Learning Vector Quantization)
- 3- RBF (Radial Basis Function).

In addition to the Delta learning rule which was used in literature intensely, 10 MLP learning rules were totally used as considering 9 algorithms used rarely in literature. 10 different backpropagation learning algorithms used in this study are as follows:

- 1- Delta
- 2- Delta-Bar-Delta (DBD)
- 3- Extended Delta-Bar-Delta (EDBD)
- 4- BFGS Quasi Newton (BFGS),
- 5- Conjugate Gradient Powell-Beale (CGPB)
- 6- Conjugate Gradient Fletcher-Rieves (CGFR)
- 7- Conjugate Gradient Polak-Ribiere (CGPR)
- 8- One Step Secant (OSS)
- 9- Resilient Backpropagation (RPROP)
- 10- Scaled Conjugate Gradient (SCG)

The input data for ANN was constructed with 6 channels of TM imagery except the 6th thermal channel. Input layer of ANN consisted of 6 neurons representing the 6 channels and The output layer of ANN consisted of 12 neurons representing the 12 classes, separately.

In ANN application, the image input data were scaled linearly $[-1 +1]$ closed interval according to the internal processing scale characteristic of ANN. The output data were set as 1 for true class and as 0 for false class.

For all MLP learning rules, 9 different net topology were used. In the unique hidden layered nets, 12, 15, 18, 24, and 30 processing elements were used in the hidden layers. In the two hidden layered nets, 9-15, 12-24, 18-24, and 24-30 processing elements were used in the first and second hidden layers, respectively.

While softmax activation function was used in the output layers of Delta, DBD and EDBD learning rules, tangent hyperbolic (TANH) activation function was used in the output layers of the other learning rules. Except the EDBD learning rule which sigmoid activation function was used in hidden layers, TANH activation function was used in the hidden layers of the other MLP learning rules.

In the application of LVQ ANN structure, LVQ1 and LVQ 2 variations of standard LVQ structure which eliminates the poor directions of standard LVQ algorithm were used in together. The network topology of LVQ in the KOHONEN hidden layer was determined by factoring the number of classes with coefficients from 1 to 24, separately. Thus the numbers of the reference vectors per class were considered in a wide range of 1 to 24.

In the RBF ANN application, the network topologies were determined using 50, 100 and 200 processing elements in the PROTO hidden layer. In addition standard RBF network, a modified RBF network was employed with an 50 processing elements in the PROTO hidden layer and 18 processing elements in the second hidden layer which behaved as a MLP hidden layer.

While Gauss based radial basis activation function was being used in PROTO hidden layer, TANH activation function was used for output layer. TANH activation function was also used in the second hidden layer of the modified RBF network.

In the training phase, the network was stopped at each 100 epoch in order to prevent the loss of generalisation ability of ANN and in these station points, the classification overall accuracy (OVA), Kappa coefficients and mean square error (MSE) values for both train and test data were computed.

For the classification problem of interest, the epoch which produced the highest test data OVA value was chosen as the optimal training epoch for that ANN structure. The performance measures for this network which would be used to compare with other networks were calculated through the network structure of this optimum epoch.

In order to examine the characteristics of the Maximum Likelihood and ANN classification methods graphically, the original feature space having 6 dimensions was reduced into the 2 dimensions. These two dimensions were selected as TM 3 and 4 channels. These channels provide higher vegetation discrimination than other

channel combinations and have generally lower correlation value. All the network topologies were reorganised suitable to this new input size. For two dimensions feature space classification, all the network topologies were redesigned as 2 processing elements for input layer, 18 processing elements for hidden layer and 12 processing elements for output layer.

In this application, the decision regions for the networks which gave the highest OVA values were examined, as well. By examining the decision regions of these algorithms, it was tried to take out their analytical characteristics of classification behaviour.


In addition to these analysis, the ground truth of the classified images in not only the train and test regions but also the rest of the images were done visually by comparing 1/5000 scaled aerial photogrammetric photographs.

Finally, the effects of continuous and stationary training strategies were compared with each other for BFGS, CGPB, CGFR, CGPR, OSS, RPROP and SCG learning rules of MLP.



1. GİRİŞ


“Uzaktan algılama arada mekanik bir temas olmaksızın bir cisimden yayılan ışıının nitelik ve nicelik yönünden değerlendirilmesi ile cismin özelliklerinin uzaktan ortaya konması ve ölçülmesidir” [1]. Uzaktan algılama çalışmaları yapay uyduların geliştirilmesinden çok daha önce 1840’larda balonlardan yeryüzünün fotoğraflarının çekilmesiyle başlamıştır. Bu ilk dönemlerde platform olarak güvercinler bile kullanılmıştır (Şekil 1.1). I. Dünya Savaşı’nda hava fotoğrafları önemli bir keşif aracı haline gelmiş ve II. Dünya Savaşı sırasında da olgunlaşmıştır. Uzaydan algılama faaliyetleri Alman V-2 roketlerine yerleştirilen otomatik foto-kamera sistemiyle başlamıştır. 1957’de fırlatılan Sputnik ile uzayda belirli bir yörüngedeki uzay aracına film kameralarının takılması mümkün olmuş ve 1960’larda meteoroloji uydularından televizyona benzer siyah-beyaz görüntüler elde edilmiştir. Operasyonel bir sistem olarak dünya hakkındaki bilgilerin periyodik toplanması, 1970’lerde SKYLAB ve LANDSAT sistemleriyle başlamıştır. Bu sistem yeryüzündeki doğal ve kültürel kaynakların belirlenmesine (haritalarının yapılması) adandı. 1978’de aynı amaçlarla bir RADAR sistemi olan SeaSAT devreye girmiştir. İlk askeri olmayan RADAR sistemi 1982’de SIR-A uydusunun fırlatılmasıyla başlamıştır.



Şekil 1.1: Uzaktan algılama platformu olarak güvercinlerin kullanımı.

Uzaktan algılamada, cisimle elektromanyetik enerji arasındaki etkileşimi kaydeden uydu ve uçaklardan elde edilen görüntü ve ilgili veriler toplanır, işlenir ve yorumlanır. Bu işlem sırasında yeryüzündeki objelerin yaydığı veya yansıttığı

elektromanyetik enerjinin yoğunluğu ölçülür ve enerji yayma veya yansıtma karakteristiğine göre objelerin özellikleri belirlenmeye çalışılır. Yoğunluğu ölçülen enerji cismin kendi yaydığı veya solar kaynaklı yansıttığı enerji ise pasif uzaktan algılama ve eğer algılayıcı sistemin kendi üretilip gönderdiği ve cisimden yansıyan enerji ise aktif uzaktan algılama söz konusudur. Her iki durumda da objelerin elektromanyetik enerjiyle (EMR) etkileşme özellikleri esastır. İdeal bir uzaktan algılama modeli, spektrumun her bölümünde ışıma yapan bir EMR kaynağı, enerjinin kaynaktan hedefe ulaşmasını sağlayacak yol, EMR'nin bilinen özellikler altında objelerle etkileşmesi ve bu etkileşen enerjinin kaydedileceği uydu platformuna yerleştirilmiş bir algılama sistemini içerir. Şekil 1.2'de uzaktan algılama modeli gösterilmektedir.



Güneşin ürettiği EMR uzay ve atmosferden geçerek yeryüzüne ulaşır. Yeryüzündeki materyallerle farklı özelliklerde etkileşen EMR yansıtılır, geçirilir ve yutulur. Yüzeye gelen enerjiye oranla bu üç farklı etkileşmenin toplamı enerjinin korunumu yasasına göre bire eşittir. Yutulan enerji cisim tarafından ısı enerjisine çevrilir ve daha büyük dalga boylarında EMR olarak yayılır. Geçirilen enerjide bir süre sonra ya yutulur veya yansıtılır. Cisimlerin EMR ile etkileşmeleri deneysel ve teorik olarak belirlenirse algılayıcı tarafından kaydedilen ışınlılık analiz edilerek yeryüzündeki objeler tanınabilir ve değişik özellikleri belirlenebilir. Böylece ortaya çıkan uzaktan algılama modeli başlıca 4 bileşenden oluşur:

1- Enerji kaynağı

2- İletim yolu

3- Hedef

4- Algılayıcı

Dünyanın enerji dengesi, iklimi, biyolojik çeşitliliği, kimyasal döngü süreçleri ve su kaynaklarının korunması ve yönetimi için global bir perspektife, bilimsel disiplinler arası yardımlaşmaya ve yeni araştırma stratejilerine ihtiyaç vardır. Uzaktan algılama bilimi bu amaçlar için global bir bakış sağlamakta ve yeni araştırma strateji ve teknikleri geliştirmede anahtar bir rol oynamaktadır.

Dünyamızın problemleri, çok geniş karasal ve deniz alanlarında iklimsel sistemleri, bölgesel su dağılımlarını, bitki örtüsü, toprak ve kayaları, ticari, politik, etnik ve dilsel sınırların hatlarını içeren coğrafi karakterli problemlerdir. Bu problemlerin nedenleri ve olası çözümleri, uzaktan algılamanın sağladığı düşük maliyetli ve hızlı sinoptik görüş ve bilgi çeşitliliği avantajıyla oluştukları gerçek coğrafya ölçeğinde araştırıldığında daha yeterli ve gerçekçi olmaktadır. Uzaktan algılama uygulamaları genel olarak şöyle sıralanabilir:

- 1- Meteoroloji; atmosferik sıcaklığın, basıncın ve su buharı içeriği profilinin belirlenmesi ve rüzgar hızı ölçümleri.
- 2- Oşinografi; deniz yüzeyi sıcaklıklarının ölçülmesi, okyanus akıntılarının ve dalga enerji spektrasının haritalanması.
- 3- Buzul bilimi; buz tabakalarının ve denizdeki buz tabakalarının hareket ve dağılımlarının haritalanması ve denizdeki buz tabakalarının navigasyon kabiliyetinin belirlenmesi.
- 4- Jeoloji, jeomorfoloji ve jeodezi; kaya tiplerinin belirlenmesi, jeolojik fayların ve anomalilerin konumlarının belirlenmesi, dünyanın şeklinin ölçülmesi ve tektonik hareketlerin gözlenmesi.
- 5- Topoğrafya ve kartografya; doğruluklu yükseklik verilerinin elde edilmesi ve bu verilerin belirli bir koordinat sistemine dönüştürülmesi, harita üretimi ve revizyonu.

6- Ziraat, ormancılık ve botanik; bitki örtüsü tipleri ve yapıları, bitkilerdeki zararlı böceklerin tanınması, toprak tiplerinin ve su içeriklerinin belirlenmesi ve haritalanması, ürün hasat miktarlarının tahmin edilmesi.

7- Hidroloji; su kaynaklarının tespiti, karın erimesiyle oluşacak su miktarının tahmin edilmesi,

8- Doğal felaket kontrolü; kum ve toz fırtınaları, çığ, toprak kaymaları ve sellerin belirlenip uyarıların yapılması, su taşkınlarının verdiği konumsal zararın görüntülenmesi, kirliliğin izlenmesi,


9- Planlama uygulamaları; arazi kullanım envanterlerinin çıkarılması ve değişimlerin izlenmesi, kaynakların belirlenmesi, trafik ölçümlerinin yapılması,

10- Askeri uygulamalar, arazi topoğrafya ve morfolojisinin belirlenmesi, askeri birliklerin ve araçların hareketlerinin izlenmesi.

Uzaktan algılamanın sağladığı çok çeşitli sinoptik karakterli bilgiler CBS (Coğrafi Bilgi Sistemleri) ortamında başka bilgilerle bütünleştirilip veya o bilgilere altlık olarak kullanılıp isteyen herkesin ulaşabileceği sistematik bir bilgi bankası oluşturulabilir. Böylece uygulamaların etkinliği süre ve maliyet açısından önemli derecede arttırılırken bilgilerin güncelliği ve buna bağlı olarak da gerçek duruma uygunluğu sağlanmış olur.

Birçok farklı disiplinden araştırmacılar uzaktan algılama görüntülerinden sınıflandırma işlemiyle elde edilen tematik haritaları kullanırlar. Görüntü sınıflandırma, uzaktan algılama görüntülerinde aynı özelliğe sahip olan bölgelerin benzer şekilde gösterildiği tematik haritaların hazırlanması işlemidir. Orijinal uzaktan algılanmış görüntü karar fonksiyonlarıyla ayrılmış özellik uzayı ile sonuç tematik haritaya dönüştürülür (Şekil 1.3). Bölgelerin ayırt edilmesinde kullanılan özellik 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 birarada 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 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 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 [2], [3]. Giriş ve çıkış verileri arasında kurulan ilişkinin anlaşılmasının genellikle mümkün olmaması YSA'ya bir kara kutu özelliği kazandırır [4]. 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.



Şekil 1.3: Özellik uzayının karar sınırlarıyla bölünerek sınıflandırma işleminin gerçekleştirilmesi.

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 ağın serbest parametrelerinin (ağırlık ve bias) belirli bir kritere göre güncellenmesidir. Ağ parametreleri kontrollü öğrenme yönteminde ağın 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 aktiflenir. Eğitim sürecinde giriş veri paternlerinden istatistiksel düzenlilik çıkarılır [5].

YSA, değişik problemlerin çözümlerinde yaygın olarak kullanılmaktadır [6]. Görüntü işleme alanında ki kullanımı, görüntü zenginleştirme ve onarımı [7], [8], patern tanıma [9] ve görüntü segmentasyonudur [10]. Paralel ağ yapısından dolayı konvansiyonel sistemlerden daha hızlı ve özellikle paralel çalışan sistemlerin bütünleşmesi için daha uygundur [5]. Çok spektrumlu uzaktan algılama uydu görüntülerinin sınıflandırılmasında YSA şu avantajlara sahiptir:

- YSA, özellik uzayının kompleks ve kaynak verinin farklı dağılımlara sahip olması durumunda klasik istatistiksel yöntemlerden daha doğruluklu sonuçlar vermektedir [11], [12].
- YSA sınıflandırma yöntemlerinin istatistiksel sınıflandırma yöntemlerine göre en büyük avantajı sınıf istatistiksel dağılımları hakkında hiçbir öncül bilgi gerektirmemeleridir. Böylece YSA yapıları dağılımdan bağımsızdır [13]. İstatistiksel yöntemler kabul edilen modele bağlı iken YSA verinin kendisine bağımlıdır [14].

- YSA, istatistiksel yöntemler için sınıflandırmada her bir veri kaynağının sahip olması gereken ağırlık değerleri hakkında hiçbir öncül bilgi gerektirmez. Böylece YSA yaklaşımı farklı kaynaklardan algılanan uzaktan algılama verilerinin sınıflandırılması için daha uygundur [15]. Bu özellik sinerjistik sınıflandırma çalışmalarının da etkinliğini arttırmaktadır [16].

Sınıflandırma, önceden tanımlanan belirli paternler arasında bir çeşit enterpolasyon problemidir. Giriş ve çıkış paternleri arasındaki kompleks ilişkiye kabul edilebilir bir yakınsama YSA tarafından adaptif bir yapıda iteratif olarak hiçbir önsel istatistiksel dağılım modeli gerektirmeden belirlenir. YSA'nın örnek paternleri kullanarak belirlediği bu model yakınsaması eğitimde kullanılmayan diğer veriler içinde kabul edilebilir sonuçlar üretebilecek seviyede bir genelleme özelliğine sahiptir.

Literatürdeki bir çok uygulamada çok spektrumlu görüntülerin sınıflandırılmasında çok katmanlı perseptron (MLP) YSA mimari yapısı ve standart geri-yayılma (Delta) öğrenme algoritması seçilmiştir [17], [18], [19], [20]. Bu tez çalışmasında çok spektrumlu bir uzaktan algılama görüntüsünün spektral tabanlı sınıflandırması için farklı YSA MLP öğrenme algoritmalarının ve farklı YSA mimari yapılarının kullanılması ve elde edilen sınıflandırma performanslarının hem kendi aralarında hem de literatürde en çok kabul görmüş klasik istatistik yöntemlerden Maksimum Olabilirlik yöntemiyle karşılaştırılması amaçlanmıştır [21], [22]. Bu amaçla MLP mimari yapısının eğitilmesi için gradiyent azaltımlı geri yayılma öğrenme algoritmasının sezgisel varyasyonları olan momentumlu geri yayılma (Delta), Delta-Bar-Delta ve Genişletilmiş Delta-Bar-Delta ve Esnek geri yayılma algoritmalarıyla birlikte ikinci dereceden nümerik optimizasyon teknikleriyle geliştirilen, Eşleştirmeli Gradiyent, Kuasi-Newton ve Ölçeklendirilmiş Eşleştirmeli Gradiyent öğrenme algoritmaları kullanılmıştır. Ayrıca MLP yapılarına ek olarak temelde bir sınıflandırma ağı olan LVQ (Learning Vector Quantization) YSA yapısı ile MLP ağlarının bir varyasyonu olan RBF (Radial Basis Function) YSA yapısı da kullanılmıştır.

Bu çalışma kapsamında çok spektrumlu görüntü verisi olarak LANDSAT TM uydusundan alınan İstanbul İkitelli civarını içeren görüntü kullanılmıştır. Kullanılan YSA mimari yapıları ve farklı öğrenme algoritmaları için farklı ağ topolojileri belirlenerek sınıflandırma problemi için optimum YSA topolojisinin belirlenmesi

amaçlanmıştır. Literatüre uygun olarak, bu çalışmada kullanılacak tüm yapılar kendi aralarında karşılaştırıldığı gibi Maksimum Olabilirlik yöntemiyle de karşılaştırılarak çalışma bölgesinde arazi kullanımına yönelik sınıflandırma problemi için YSA'nın Maksimum Olabilirlik yöntemine göre avantaj ve dezavantajları irdelenmiştir.



2. UZAKTAN ALGILAMANIN FİZİKSEL TEMELLERİ

2.1. Elektromanyetik Enerji

Elektromanyetik enerji, uzaktan algılama sisteminin bileşenleri arasındaki bağlantıyı oluşturur. Enerji, iş yapabilme kabiliyeti olup bir noktadan diğer bir noktaya konveksiyon, kondüksiyon ve ışımayla taşınır. Uzaktan algılamada, enerjinin ışımayla taşınması (elektromanyetik ışıma-EMR) önemlidir. Elektromanyetik ışıma enerjinin dinamik formudur [23].

Yapılan çalışmalar, elektromanyetik enerjinin hem dalga hem de parçacık karakterli olduğunu göstermiştir. Uzaktan algılama için enerjinin bu dualitesi bir paradoks değil aksine tam bir uygunluk göstermektedir. Dalga karakteriyle elektromanyetik spektrum oluşturulurken, parçacık karakteriyle de elektromanyetik enerjinin atmosfer ve yeryüzüyle etkileşimi açıklanmaktadır. EMR'nin dalga formunda sürekli modeli Maxwell tarafından araştırılmıştır. Elektromanyetik bir dalga hem birbirlerine hem de yayılma doğrultusuna dik olan elektrik (E) ve manyetik (M) alanlardan oluşmaktadır. Şekil 2.1'de dalga karakteri için geçerli olan birbirine dik manyetik (M) ve elektrik alan (E) düzlemleri gösterilmektedir.

Elektromanyetik enerjinin yayılma hızı aynı ortam içinde her yerde sabittir. Vakum ortamdaki hızı $3 \cdot 10^8$ m/sn'dir. Dalga boyu (λ), frekans (ν) ve genlik (A) enerjinin dalga karakterini ifade etmek için kullanılan parametrelerdir. Dalga boyu, birbirini takip eden dalga tepeleri arasındaki mesafedir. Frekans belirli bir noktadan birim zamanda geçen tam dalga boyu sayısıdır. Genlik, dalganın ortalama konumundan olan maksimum açılımıdır. Periyot ise dalga formunun diğer bir ölçüm parametresi olarak, belirli bir noktadan tam bir dalga boyunun geçmesi için gereken zamandır. Periyot ile frekans arasında $T=1/f$ ilişkisi vardır.

EMR'nin parçacık karakteri Planck tarafından açıklanmıştır. Parçacık anlamında enerji sürekli dalgalarla aynı doğrultuda ve hızda yayılan küçük parçacıklar


(kuantum) olarak düşünülür. Her bir ışına parçacığının sahip olduğu enerji foton olarak adlandırılır. Dalga formundaki enerji miktarı, genliğin karesiyle doğru orantılıdır. Buradan hız (c);

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

eşitliği ile elde edilir. Tek bir foton için dalga formunun taşıdığı enerji veya genliğinin karesi;

$$E = h\nu \\ = h \frac{c}{\lambda} \quad (2.2)$$

ile ifade edilir. Burada h, Planck sabitidir. Elektromanyetik enerjinin cisimlerle olan etkileşimi parçacık formunda kuantum teoremiyle açıklanır ve yukarıdaki enerji denklemiyle matematiksel olarak ifade edilir. Planck eşitliği, metal bir yüzeye çarpan fotonun (kuanta) elektron emisyonuna neden olduğunu ifade eden fotoelektrik etkiyi açıklamaktadır. Bu eşitlik aynı zamanda EMR'nin parçacık ve dalga karakteri arasındaki bağlantıyı da göstermektedir. Enerji, frekansla doğru ve dalga boyu ile ters orantılı olduğundan artan dalga boyuyla enerjide bir azalma gözlenmektedir.




Şekil 2.1: Elektromanyetik enerjinin dalga karakteri.

2.2. Elektromanyetik Spektrum

Elektromanyetik enerji spektrumu 10^{-10} μm dalga boylarından (kozmoz ışınlar) 10^{10} μm dalga boylarına kadar (radyo dalgaları) olan sürekli bir enerji ortamıdır. Uzaktan algılamada, özellikle 0.3-15 μm arasındaki optik dalga boyları ile 1-1000 mm

arasındaki mikrodalga bölgeleriyle ilgilenilmektedir. Şekil 2.2’de elektromanyetik spektrum verilmektedir.



Şekil 2.2: Elektromanyetik spektrum

Optik bölgenin 0.38-3 μm arasındaki bölge yansıtıcı bölgedir. Bu dalga boylarında algılanan enerji öncelikle güneşten kaynaklanan ve yer yüzündeki cisimlerden yansıyan ışınımdır. Yansıtıcı bölge, görünür (0.38-0.72 μm) ve yansıtıcı (0.72-3 μm) kızıl ötesi bölgelere ayrılır. Yansıtıcı kızılötesi bölge, yakın kızılötesi (0.72-1.3 μm) ve orta kızılötesi (1.3-3 μm) bölgelerden oluşmaktadır [24]. Elektromanyetik spektrumun farklı bölgelerinde oluşan EMR farklı objelerle değişik karakterde etkileşmektedir. Örneğin, görünür ve yakın kızılötesi bölgede EMR bitki örtüsünün nem içeriği, pigmentasyon ve hücresel yapısına ve toprağın nem ve mineral içeriğine bağlıdır. Yüzeylerin ısı özellikleri en iyi uzak kızılötesi bölgede ayırt edilebilmektedir. Yüzeylerin elektriksel özellikleri ve pürüzlülüğü ise elektromanyetik spektrumun mikrodalga bölgesinde analiz edilebilmektedir. Bunun sonucu olarak farklı algılama sistemleri spektrumun farklı bölgelerinde objelerin yaydığı ve yansıttığı enerjiyi kullanarak, farklı kimyasal ve fiziksel yapıdaki objelerin özelliklerini belirlemek ve birbirlerinden ayırt etmek için tasarlanmaktadır. Spektrumun mor-ötesi (UV) bölgesindeki EMR, atmosfere nüfuz edemediği için uzaktan algılamada kullanım alanı bulmamaktadır.

2.3. Standart Terimler ve Birimler

Uzaktan algılamadaki algılama sistemleri insan gözünden farklı oldukları için fotometrik birimler yerine radyometrik birimler kullanılır [24]. Tablo 2.1’de radyometrik terimler birimleriyle birlikte verilmektedir [25].

Tablo 2.1: 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	$\frac{d^2\Phi}{\cos\theta dA d\omega}$ (dışarı)	Metrekaredeki Steradyandaki Vat
M_λ	Spektral ışınır çıkış	$\frac{dM}{d\lambda}$ (dışarı)	Metre karedeki Mikrometredeki Vat
E_λ	Spektral birim ışınırılık	$\frac{dE}{d\lambda}$ (içeri)	Metre karedeki Mikrometredeki Vat
L_λ	Spektral ışınırılık	$\frac{dL}{d\lambda}$	Metre karedeki 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 [23]. 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 2.2’de verilmektedir [23].

Tablo 2.2: Oransal radyometrik terimler.

NİCELİK	EŞİTLİK
Yayım(ϵ)	$M/M_{\text{siyahcisim}}$
Yansıtım(ρ)	Φ_r/Φ_i
Yutulum(α)	Φ_a/Φ_i
Geçirim(τ)	Φ_t/Φ_i

Burada M ve $M_{\text{siyahcisim}}$ sırasıyla ölçülen objenin ve aynı sıcaklığa sahip bir siyah cismin ışıdır çıkışlarıdır. Φ_i ise, gelen akıdır.

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

2.4. Uzaktan Algılamada Spektral Bölgeler

Tablo 2.3’de uzaktan algılamadaki önemli spektral bölgeler gösterilmektedir. Bu özel spektral bölgeler rölaf olarak geçirimli atmosfer pencerelerini içermektedir. Mikrodalga bölge hariç bulut gibi etkenlerin olmadığı zamanlarda bu pencerelerden yeryüzü gözlenebilmektedir. Atmosfer pencerelerinin arasında su buharı ve karbondioksit gibi etkenler enerjide yutulmaya neden olmaktadır. Özellikle 2.5-3 μm ve 5-8 μm bölgelerinde yutulma oluşmaktadır. Mikrodalga bölgesinde ise 22 GHz frekans yakınında (1.36 cm dalga boyu) 0.85 oranında geçirimli küçük bir su yutulması vardır [26]. 50 GHz’in üstünde 80 GHz’e kadar olan bölgede ise asıl oksijen yutulması mevcuttur. [27]. Yüksek atmosferik geçirgenliğin olduğu mikrodalga bölgesinde algılama sistemleri her türlü hava koşulunda (bulutlu, yağmurlu veya sisli gibi) ve gündüz-gece çalışabilmektedir.

Pasif uzaktan algılama sistemlerinde, algılayıcılar yeryüzü, atmosfer ve bulutlardan doğal olarak yansıyan veya yayılan enerjiyi ölçerler. Görünür, yakın kızılötesi ve kısa dalga kızılötesi bölgeleri (0.4-3 μm) güneş ışığını yansıtan spektral bölgelerdir. Bu bölgelerde dünya yüzeyine güneşten gelen enerji miktarı, dünyanın kendi yaydığı enerjiden çok daha fazla ve baskın olmaktadır. Orta kızılötesi bölge, yansıtıcı bölgeden ısıl bölgeye bir geçiştir. 5 μm ’nin üstünde dünyanın kendi yaydığı enerji genel olarak daha baskındır. Bu fenomenden dolayı ısıl kızılötesi bölgede gündüz ve

gece algılama yapılabilmektedir. Yayılan enerji mikrodalga bölgesinde, mikrodalga parlaklık sıcaklığı olarak pasif algılama sistemleri tarafından algılanabilir [28]. Tablo 2.3’de uzaktan algılamada kullanılan önemli spektral bölgeler verilmektedir.

Tablo 2.3: Uzaktan algılamada kullanılan başlıca spektral bölgeler.

SPEKTRAL BÖLGE	DALGA BOYU (μm)	İŞİMA KAYNAĞI	YÜZEY ETKİLEŞİMİ
Görünür(V)	0.4-0.7	Solar	Yansıtım
Yakın kızılötesi (NIR)	0.7-1.1	Solar	Yansıtım
Kısadalga kızılötesi (SWIR)	1.1-1.35 1.4-1.8 2-2.5	Solar	Yansıtım
Orta dalga kızılötesi (MWIR)	3-4 4.5-5	Solar, termal	Yansıtım, Sıcaklık
Isıl kızılötesi (TIR)	8-9.5 10-14	Termal	Sıcaklık
Mikrodalga, Radar	1mm-1m	Termal (pasif) Yapay (aktif)	Sıcaklık (pasif) Pürüzlülük (aktif)

Aktif uzaktan algılamada, yapay enerji kaynakları kullanılır. Algılayıcı sistemin kendi kaynaklarıyla üretilip gönderdiği sinyalin geri dönen (saçılan) kısmı, objenin (yeryüzü veya atmosfer) farklı özelliklerini ortaya koymaktadır.


2.4.1. Atmosfer Pencereleeri

EMR’nin atmosferden oldukça az bir zayıflama ile geçtiği bölgeler atmosfer pencereleeri olarak adlandırılır. Oksijen, karbondioksit, ozon ve su buharı asıl yutucular olup, uzaktan algılama için uygun moleküler yutulma kanallarıyla belirlenen atmosfer pencereleeri Tablo 2.4’de verilmektedir.

Tablo 2.4: Atmosfer pencereleeri.

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

Atmosferin geçirimsizliği, bakış açısı ve buna bağlı olarak atmosferde enerjinin kat ettiği yol uzunluğu ile değişmektedir. Şekil 2.3’de algılayıcının gördüğü atmosferik yol geçirimsizliği verilmektedir.



Şekil 2.3: Uydu bakış açısına göre atmosferik yol geçirimi.

Küçük bakış açılarında (FOV), duman ve pusan hariç görüntü bütününde atmosferik şartlar aynıdır. Böyle algılamalarda topoğrafik rölyef ötelemesi küçükse atmosferik geçirim yolu bütün pikseller için hemen hemen aynıdır. Yüksek arazi rölyefinin olduğu yerlerde bakış açısı küçük olsa bile pikselden piksele olan yükseklik değişiminden dolayı atmosferik değişim pikselden piksele farklılık göstermektedir [29].

2.5. Optik EMR Modelleri

Görünürden (V) ısı kızılotesine (TIR) kadar uzanan optik bölgedeki pasif uzaktan algılama teknikleri iki EMR kaynağına bağlıdır; görünürden kısa dalga kızılotesine kadar olan bölgedeki solar kaynaklı EMR ve objelerin kendilerinin yaydıkları ısı EMR. Solar kaynaklı EMR'nin değerlendirildiği birinci bölgede, yeryüzünden ve yeryüzüne ulaşmadan doğrudan atmosferden yansıtılarak algılayıcıya ulaşan EMR üzerinde atmosferik etkiler vardır. Isıl bölgede ise doğrudan objelerin yaydıkları EMR, atmosferik ısı yayılımıyla birleşerek algılayıcıya ulaşır.

2.5.1. Görünür-Kısa Dalga Kızılotesi Bölge


Güneş, en baskın ışıma kaynağı olarak hayatın devamı için ihtiyaç duyulan enerjiyi sağlar. Atmosferi oluşturan gazlar güneş spektrumunu etkilemekte ve karmaşık bir yapı kazandırmaktadır. Atmosferin dış sınırındaki kozmik güneş spektrumunu çok düzgündür ve yaklaşık 6000 °K bir sıcaklığa sahip ideal bir siyah cisim tarafından

ışınlanan ışıma benzer. Uzaktan algılamada güneş spektrumunun ideal bir siyah cisim ışınlayıcı gibi yorumlanması uygundur. Plank'ın siyah cisim eşitliğiyle modellenirse [30];

$$M_{\lambda} = \frac{c_1}{\lambda^5 (e^{\frac{c_2}{\lambda T}} - 1)} \quad (2.3)$$

elde edilir. Burada T; siyah cismin Kelvin biriminde sıcaklığı, $C_1=3,74151 \cdot 10^8 \text{ W} \cdot \text{m}^2 \cdot \mu\text{m}^4$ ve $C_2=1,43879 \cdot 10^4 \mu\text{m} \cdot ^\circ\text{K}$ dir.

Şekil 2.4'de atmosferden geçerek yer yüzüne ulaşan güneşin spektral birim ışınlılık eğrisi verilmiştir [24].




Şekil 2.4: Yüzeydeki bir hava kütesinden geçen güneş kaynaklı EMR'nin yeryüzündeki spektral birim ışınlılığı.

Güneşten gelen bütün EMR, yeryüzündeki objeler ve bu objelerle etkileşmeden önce ve etkileştikten sonra atmosfer tarafından pasif olarak yutulur, yansıtılır ve geçirilir. Bu etkileşme sonucunda enerjinin hızında, frekansında, yoğunluğunda, spektral dağılım ve doğrultusunda değişimler olur. Bu etkiler en çok 0.4-3 μm aralığındaki görünür ve kısa dalga kızıl ötesi bölgede yapılan ölçmeler için önemlidir. Mikrodalga bölgesinde ise atmosfer etkisi göz önüne alınamayacak kadar düşüktür. Uydu algılayıcısına gelen ışınlılık üç ana bileşenden oluşmaktadır [30]:

- Saçılmayan yüzeyden yansıyan enerji

- Aşağı yönlü saçılan yüzeyden yansıyan enerji
- Yukarı yönlü saçılan yüzeyden yansımayan enerji

Toplam ışınlılık bu üç bileşenin toplamına eşittir. Şekil 2.5'te solar yansıtım bölgesindeki ısıma bileşenleri gösterilmektedir.



Şekil 2.5: Solar yansıtım bölgesindeki ısıma bileşenleri.

Su ve karbondioksitin moleküler yutulma kanalları 1.4 ve 1.9 μm civarında derin yutulma özellikleri ortaya koyar ve bütün olarak enerji geçirimi bloke edilir. Bu nedenle bu bölgelerde algılama yapılamaz. Bununla beraber bu bölgelerdeki algılama sirrus tipi bulutların saptanmasında kullanılabilir [31]. Geçirim, genel olarak mavi spektral bölgeye doğru azalır. Bu, özellikle çapı λ/π 'den daha az olan hava moleküllerinden dolayı solar yoldan saçılan ışığın sonucudur [32]. Bu büyüklükte moleküler saçılma dalga boyunun λ^{-4} 'e bağlı Rayleigh saçılımı olarak adlandırılır. Bu nedenle daha kısa dalga uzunluklu mavi ışık kırmızıya göre daha çok saçılır. Buda mavi gök yüzünün ve güneşin doğuş ve batış anındaki kızıllığın sebebidir. Dalga boyu azaldıkça saçılma oranı artar. Yeryüzünden 9-10 km yükseklikte baskındır. Daha aşağıdaki (0-5 km) atmosferde bulunan parçacıklar (duman, sis, toz, pus, dumanlı sis) Mie saçılımına neden olur. $\frac{2\lambda}{\pi}$ 'den daha büyük parçacıklar için Mie saçılımının büyüklüğü dalga boyuna bağlı değildir. Su damlalarının enerjiyi

bütünyle saçmasından dolayı ince bulutlar beyaz renkte görünür. Büyüklükleri $\frac{\lambda}{\pi}$

ve $\frac{2\lambda}{\pi}$ arasında kalan partiküller için dalga boyuna olan bağımlılık Rayleigh saçılımı için olandan daha azdır. Bütünyle moleküler ve partiküllerden oluşan gerçek atmosferde, Rayleigh ve Mie saçılımı birlikte görülür. Partiküller gelen EMR'nin dalga boyundan daha büyükse, EMR dalga boyundan bağımsız olarak saçılır ve alt atmosferde pusa neden olur.

2.5.2. Orta Dalga Kızılötesi - Isıl Kızılötesi Bölge

Orta dalga kızıl ötesi ve ısı kızıl ötesi bölgede obje içindeki moleküllerin kinetik enerjisinden dolayı mutlak sıfırın üstünde bir sıcaklığa sahip bütün objeler ısı enerji yayar. Bu ışımanın dağılımı değişen dalga boyuyla birlikte düzenli olarak değişim göstermez. Eğer obje ideal bir siyah cisim ise, enerji ışıması Planck denklemine uygunluk gösterir. Siyah cisim teorik olarak mükemmel bir yutucu ve yayıcıdır. Siyah cisim ışımasının maksimum olduğu dalga boyu, Wien Yer Değiştirme Kanunu ile adlandırılan eşitlik ile belirlenir:

$$\lambda_{maks} = \frac{2898}{T} \quad (2.4)$$

Burada T; siyah cisim sıcaklığı ve λ_{maks} ; ışımanın maksimum olduğu dalga boyudur. Eşitlikten, siyah cismin sıcaklığı arttıkça maksimum ışıma çıkışın dalga boyunun azaldığı görülmektedir. Ayrıca Planck kanununun frekans formu kullanılarak tüm frekanslara göre integrali alındığında ve gerekli düzenlemeler yapıldığında, siyah cisim için;


$$M = \epsilon \sigma T^4 \quad (2.5)$$

eşitliği elde edilir. Stefan-Boltzman olarak adlandırılan bu eşitlik, T sıcaklığına sahip bir siyah cisim için olan toplam spektral ışıma çıkışı göstermektedir. Burada, $\sigma = 5.6697 \cdot 10^{-8} \text{ W-m}^{-2}\text{-K}^{-4}$ olup ϵ ise, yayımı ifade etmektedir. Siyah cisim için geçerli olan yukarıdaki bağıntıları yeryüzü materyalleriyle ilişkilendirmek için yayım (ϵ) parametresi kullanılır [24]. Yayım, ideal siyah cisim için 1'e eşit olup ($\epsilon = 1$), diğer cisimler (gri cisim) için 0 ve 1 arasındadır ($0 < \epsilon < 1$). İdeal siyah cisim

mükemmel yutucu ve yayıcıdır. Sıfır yayıma sahip bir cisim yansıtımı 1 olan ($\epsilon = 0$) mükemmel bir yansıtıcıdır. Planck kanunundan farklı bir fonksiyonel formda bir spektral ışıma çıkış eğrisine sahip olan cisimler için yayım, $\epsilon = f(\lambda)$ ile ifade edilir.

Gerçek objeler mükemmel yayıcı ve yutucu olmadıklarından bir yayım etkinlik faktörüne bağlı olarak (genel olarak dalga boyunun fonksiyonu) değişim gösterir. Gerçek objeler gri cisimler olup, spektral ışıma çıkışın yayımı, dalga boyu bağımlılığından dolayı siyah cismin yayımına benzeşim göstermez. Toplam yayılan ışıma; (i) dünya yüzeyinden yayılan, (ii) aşağı yönlü yayılan yüzeyden yansıyan ve (iii) atmosferde yayılan ışıma enerji bileşenlerinin toplamına eşittir. Orta dalga kızıl ötesi bölge bir geçiş bölgesi olduğundan bu bölgedeki toplam ışıma, toplam yansıyan ışıma ile toplam yayılan ışımanın birleşimidir.

Isıl bölgede solar yansıyan kısım ihmal edilebileceğinden, toplam ışıma, doğrudan toplam yayılan ışıma ile eşitlenebilir. Isıl algılama için asıl kaynak dünyanın kendisidir. Yeryüzünün yaydığı ışıma çıkış 300 K sıcaklığında ideal siyah cisimle modellenir. 3-50 μm arasında 9.7 μm de maksimum enerji ışıması olur. Yeryüzü düşük frekanslı uzun dalga boylu ve dolayısıyla düşük enerjili bir ışıma yaptığından bu enerjinin algılanması zordur. Şekil 2.6'da yeryüzü ve güneşin sıcaklıklarına eşdeğer siyah cisim ışıma eğrileri verilmektedir.




Şekil 2.6: Güneş ve yer yüzeyi sıcaklıklarında siyah cisim ışıması.

Isıl bölgede solar enerji dağılımı düşüktür ve 2.5 μm 'den itibaren ani bir azalma gösterir. Aynı sıcaklıkta olmalarına rağmen farklı malzemeler değişik miktarlarda enerji yayar. Bu farklılık cisimlerin yayım parametresine bağlıdır. Yayım, görünür bölgedeki yansıtımın oransallık etkisine benzer olarak ısıl bölgede etkindir. Yer

yüzündeki materyaller farklı yayım katsayılarına sahip oldukları gibi farklı sıcaklıklara ve böylece de farklı spektral ışıdır çıkışlara sahiptir [30].

Yayım ve sıcaklığın etkilerini birbirinden ayırt etmek için uygulamada genel olarak yayım veya sıcaklığın mekansal olarak sabit olduğu düşünülür. Binalardaki ısı kaybının araştırılması gibi uygulamalarda farklı çatı tiplerinin aynı yayım katsayısına sahip oldukları kabul edilir (sıcaklığı belirlemek için). Diğer taraftan bazı jeolojik uygulamalarda ise yayımı belirlemek için sıcaklık sabit alınır. Isıl kızılötesi kanal boyunca 2.5 μm 'den itibaren atmosferin geçirimsizliği Şekil 2.7'de gösterilmektedir. Bu şekil atmosferik modelleme programı MODTRAN'dan elde edilmiştir [33].



Şekil 2.7: Atmosferin orta ve ısı kızılötesi bölgedeki geçirimsizliği.

Isıl bölgede 8-14 μm arasında geçirim pencereleri vardır. Ozon gazından dolayı 9.6 μm civarında 9.5 μm 'de merkezlenmiş dar bir yutulma bandı vardır. Uzun dalga boyuna sahip enerjinin yutulması atmosferde ısınma etkisi oluşturur. Karbondioksit ve su buharı ozonla beraber asıl yutma elemanlarıdır. Geçtiğimiz yüzyılda fosil yakıtların yakılması sonucu atmosferde artan karbondioksit oranının atmosferin doğal dengesinin bozulup daha fazla ısınmasına ve dolayısıyla iklimler üzerinde değişikliklere neden olduğu görülmüştür.

2.6. Cisimlerin Spektral Özellikleri

2.6.1. Bitki Örtüsünün Spektral Özellikleri

Bir bitki örtüsü kanopisinin spektral yansıtımı dalga boyuna bağlı olarak değişim göstermektedir. Pigmentasyon, fizyolojik yapı ve su muhtevası bitki örtüsü kanopisi için yansıtımda, yutulmada ve geçirimde önemli etkiye sahiptir.

Görünür bölgede, bitkiler için pigmentasyon önemlidir. Bu pigmentler içinde en önemlisi klorofildir. Enerji 0.43, 0.66 μm ve 0.45, 0.65 μm civarında yutulur. Buna karşılık diğer bölgelerde ise yutulma azalır, yansıtım ve geçirim artar. Bu yüzden sağlıklı normal yapraklar gözümüze yeşil renkte görünür.

Yakın kızılötesi bölgede (kısa dalga kızılötesi bölgede dahil) yaprağın fizyolojik yapısı yansıtımı etkileyen faktördür [34], [35], [36], [37]. Yaprak pigmentlerinin ve fizyolojik yapının ortak etkisi bütün sağlıklı yeşil yapraklara karakteristik yansıtım özellikleri verir. Türler arasında yaprak yansıtımındaki önemli farklar hem pigment içeriğini hem de fizyolojik yapıyı etkileyen yaprak kalınlığına bağlıdır.

Yakın ve orta kızılötesi bölgede 1.4, 1.9 ve 2.7 μm civarındaki asıl ve 0.9 ve 1.1 μm civarındaki ikincil yutulma kanallarının sonucu olarak yaprak yansıtımı azalır. Orta kızılötesi bölgede yansıtım su miktarına ve buna bağlantılı olarak da yaprak kalınlığına bağlıdır. Su miktarı arttıkça yansıtım azalmakta ve yutulma artmaktadır.

Bir bitki örtüsü kanopisi, geniş tek bir yapraktan ziyade birçok yaprağın mozaikinden, diğer bitki yapılarından, zemin yapısından ve gölgeden oluşan karmaşık bir yapıdır. Bu nedenle tek bir yaprağın yansıtımı ile bitki örtüsü kanopisinin iki boyutlu yansıtımını (BR) açıklamak yeterli olmayacaktır. Algılayıcının kaydettiği yaprak yansıtımı kanopi içerisindeki yaprakların alanlarıyla ilişkili olup, yaprakların alanları yaprak alan indeksiyle (LAI) sayısal olarak elde edilebilmektedir. Bu indeks, birim alan içindeki birim yaprak alanını ifade eder [38]. LAI oranı yükseldikçe kanopi yansıtım karakteristiği tek bir yaprak için olan yansıtım özelliğine yaklaşım gösterir.

Bitki örtüsünün yaşlanması veya ürünün olgunlaşmasıyla olan değişimlerin yakın kızılötesi bölgede yansıtıma önemli bir etkisi yoktur. Bitki örtüsü enerjiyi bütün

doğrultularda eşit olarak yansıtmadığından güneşin ve algılayıcı yüksekliğinin yansımaya etkisi göz önünde bulundurulmalıdır. Güneş yüksekliğinin fazla olması durumunda, ışıınım kanopinin içine nüfuz edecek ve yansıtım düşecektir. Ters durumda ise yansıtım artacaktır. Buna karşın görünür bölgede kanopi geometrisine bağlı olarak gölgeler oluşmakta ve yansıtımda azalma görülmektedir. Yakın kızılötesi bölgede ise gölge etkisi daha azdır. Algılayıcının yüksekliği arka plandaki görünür toprak miktarını etkilemektedir. Genel olarak kanopi geometrisi, yaprakların geçirimi, yaprak tabakalarının sayısı, bitki üzerindeki yaprakların dizilimi ve arka plandaki yapının karakteri (toprak, yaprak vb.) yansıtımı etkileyen faktörlerdir [23].

Isıl kızılötesi bölgede bitki örtüsü kanopisinin ısı özellikleri suyun veya toprağın özelliklerine nazaran daha karmaşıktır. Bunun nedeni, görünür bölgede bitki örtüsünün solar enerjinin büyük bir kısmını yutması ve enerji dengesine bağlı olarak ısıl bölgede yayım yapmasıdır. Bitki örtüsü kanopisinin sıcaklığı, geniş yüzey alanına ve yüksek terleme oranına bağlı olarak değişir. Bu sebeple bitki örtüsü kendisini çevreleyen topraktan 30 kat daha fazla bir ısıma oranına sahiptir [39]. Genel olarak ısıl bölgede yapılan algılamalarda; (i) toprak sıcaklığı, (ii) algılayıcı açısı, (iii) bitki örtüsü tipi ve (iv) bitki örtüsünün nem içeriği gibi problemlerle karşılaşilmektedir [32].

2.6.2. Toprağın Spektral Özellikleri

Zeminlere ait yansıtım eğrilerinin genel özelliği, yansıtmanın artan dalga boyuna bağlı olarak artım göstermesidir. Zeminler için sadece yansıtma ve yutma söz konusu olup, zeminin üst tabakalarının bileşimi yansıtma önemli rol oynamaktadır. Genel olarak zeminlerin yansıtma özellikleri; (i) zeminin su muhtevasına, (ii) zemini oluşturan minerallerin cins ve miktarına, (iii) doku ve yüzey pürüzlülüğüne ve (iv) organik madde muhtevasına bağlıdır [1], [40], [41], [42], [43], [44], [45], [46].

Genel anlamda bir zeminde su muhtevası arttıkça yansıtım özelliği azalmakta olup, bu azalma toprak doygunluğa ulaşmaya kadar sürmektedir. Bu bağlamda kuru bir zemin, ıslak bir zemine göre daha fazla yansıtıma sahiptir. Yakın kızılötesindeki toprak yansıtımı da içerdiği nem muhtevasıyla ters ilişkilidir. Nem muhtevasındaki artış, su ve hidroksildeki yutulma kanallarından dolayı yansıtımda ani, hızlı bir düşmeye neden olmaktadır.

Topraktaki organik madde koyu renkli olup yansıtımı azaltan bir etkiye sahiptir. Organik madde muhtevası %5 den fazla olduğunda toprak siyah görünür ve bu değerden sonra organik madde miktarındaki herhangi bir artış yansıtımda az bir etkiye sahiptir. Demir oksit yeşil ışığı yutarken kırmızı ışığı yansıtır ve çoğu toprağa paslı kırmızımtırak bir renk verir [47]. Bu etkileşimin sonucu olarak, kırmızı bölge yansıtımının yeşil bölge yansıtımına oranı demir cevheri yataklarının belirlenmesinde kullanılmaktadır.

Isıl kızılötesi bölgede toprağın ısıma sıcaklığı (T_{rad}), asıl olarak nem muhtevasıyla belirlenir. Su muhtevası fazla olan zeminler buharlaşma nedeni ile soğuyacaklarından koyu renk tonunda, kuru zeminler ise güneş enerjisini yutup ısındıklarından ve buharlaşma gibi bir nedenle de soğumadıklarından açık renk tonunda görünür.

2.6.3. Suyun Spektral Özellikleri

Bir su kütlesinin yansıtımındaki uzaysal değişkenliği etkileyen faktörler; (i) su derinliği, (ii) su içerisindeki materyaller ve (iii) suyun yüzey pürüzlülüğüdür (dalgalılık) [1].

Sığ yüzeylerde yansıtım su yüzeyinin yanısıra su tabanı ile de ilişkilidir. Sığ su kütlelerinde yansıtım, su taban yapısının yansıtım özellikleri tarafından etkilenmektedir. Su içerisinde askıda olan materyallerin başında organik olmayan sedimentler, tanin ve klorofil gelir. Askıdaki materyallerin düzenli dağılmış olması, yatay veya düşey dizilimli olması, veya heterojen veya homojen dağılmış olması yansıtımda değişimlere neden olmaktadır. Görünür bölgede, organik olmayan (suyun sürüklediği çamur ve balçık) objeler saçılmayı ve yansımayı artırıcı özelliğe sahiptir. Klorofil içeren yeşil bitki örtüsünün bulunduğu su kütlelerinde yeşil bölge yansıtımında artma ve mavi ve kırmızı bölgelerdeki yansıtımda ise azalma meydana gelmektedir.

Eğer dalga az veya hiç yok ise yansıma tam yansıma karakteri gösterir. Algılayıcının konumuna göre bu etki ya çok fazla yada çok az bir yansıtıma neden olur. Yüzey, kaba yani dalgalı olduğunda saçılma olur ve algılayıcı konumuna bağlı olmaksızın yansıtım artar. Su kütlelerinde yansıtım; (i) yüzey yansıması, (ii) hacim yansıması,

(iii) taban yansıması olarak üç gruba ayrılır. Bu yansılardan sadece hacim yansıması su kalitesiyle ilgili bilgi içermektedir [48]. Hacim yansımasında suyun içine nüfuz eden enerji dalga boyuna bağlı olarak, özellikle çözölmüş materyallerce yutulmakta ve yine çözölmemiş askıdaki cisimler tarafından yansıtılmaktadır.


Klorofil nedeniyle olan yansıma askıdaki sedimentin neden olduđu yansımadan daha düşük olup 0.64-0.69 μm arasındadır. Bu ise, algılayıcının spektral çözönlölüğünün yüksek olmasını gerektirir.

Su, yakın kızılötesi ve orta kızılötesi bölgelerde güçlü yutulmaya sahip olduğundan, su kara ayrımı bu bölgelerde kolaylıkla yapılabilir. Isıl kızılötesi bölgede su, toprağa benzeyen bir ısıl ivmeye sahiptir. Ancak sabit bir yüzey sıcaklığına sahip olmasını sağlayan iç konveksiyonu olduğü için, çok daha küçük günlük ısıl değışime sahiptir.



3. UZAKTAN ALGILAMA UYDU SİSTEMLERİ

Uydu algılama sistemleri yansıtılan veya yayılan ışınlılığı, ışınlılığın uzaysal dağılımını oluşturan görüntüye dönüştürür. Bu dönüşüm aşamasında algılanan ışınlılığın radyometrik, geometrik ve uzaysal özelliklerinde önemli dönüşümler yapılır. Bu dönüşümler sonucunda toplam ışınlılığın ilgilenilen kısımdaki sinyalde bozulmalar oluşur. Bu bozulmanın karakterinin anlaşılması görüntü işleme algoritmalarının düzenli tasarlanması ve görüntülerin yorumlanması açısından önemlidir. Genel olarak tarayıcıların kullanıldığı elektro-optik bir algılayıcı Şekil 3.1’de görüldüğü gibi modellenenabilir [30].



Şekil 3.1: Elektro-optik uzaktan algılama sisteminin ana bileşenleri.

İlgilenilen objeyle uydu sistemi arasında bilgi iletimini sağlayan EMR, detektörlerce algılanır ve elektron akımına veya saptanabilir diğer elektriksel işaretlere dönüştürülür. Tarama işlemiyle sürekli zamansal bir elektronik sinyale dönüştürülen uzaysal bilgi daha sonra A/D dönüştürücülerle işlenerek görüntü piksellerini temsil eden ayrık dijital sayılara (DN) kuantize edilir.


Uydu algılama sistemleri algılanılan ışınlılığın kaynağına göre aktif ve pasif sistemler olarak ikiye ayrılır. Pasif sistemler cisimden yansıyan ve/veya yayılan enerjiyi algılayan elektro-optik sistemlerdir. Aktif sistemler ise, sistem tarafından üretilip objeye gönderilen ve cisimden yansıyıp tekrar algılanarak bilginin elde edildiği sistemlerdir. Pasif uydu sistemleri elektromanyetik spektrumun görünür ve

kızılötesi bölgelerinde, aktif uydu sistemleri ise mikrodalga bölgede kullanılmaktadır. Optik algılayıcılar ısı ve foton detektörlerle çalışırken mikrodalga bölgede detektör yerine anten kullanılmaktadır [1].

Uydu uzaktan algılama sistemleri görüntü üreten ve üretmeyen sistemler olarak da sınıflandırılabilir. Görüntü üreten sistemler yeryüzünün algılanan kısmının iki boyutlu görüntüsünü, görüntü üretmeyen sistemler ise belirli parametreler hakkında bilgi üreten sistemlerdir. Örneğin yeryüzünden olan uydu yüksekliği veya deniz yüzeyi dalgallılığını ifade eden değerler gibi. Görüntünün sağladığı bilgi çok daha zengin ve görsel olarak yorumlanabilir olmakla beraber, gerekli radyometrik ve geometrik düzeltmeler ile değişik kullanım amaçlı uygulamalar için daha sofistike matematiksel analiz tekniklerine gereksinim duyulmaktadır.

3.1. Uzaktan Algılama Sistem Karakteristikleri

Piksellere atanan sonuç değerler, uzay, dalga boyu ve zaman boyutlarının her birinin etkilerini içerir. Zamanın etkisi genellikle çok küçüktür ve çoğu uygulamada ihmal edilebilir. Örneğin LANDSAT TM için mikrosaniye ve SPOT için milisaniyedir. Uzay ve dalga boyu üzerindeki etkiler, bu kritik boyutlardaki veri karakteristiklerini tanımlar. Uzaysal koordinatlar (x,y) üzerinde dalga boyu (λ) ile tanımlı üç boyutlu dijital görüntüdeki her bir piksel, Şekil 3.2’de görüldüğü gibi görselleştirilebilir.



Şekil 3.2: Dijital uydu görüntü verisinin (x,y,λ) boyutlarında görselleştirilmesi.

C kanal sayısı, algılayıcı sistemler arasında ayırt edici bir özelliktir. Örneğin LANDSAT TM 7 farklı spektral kanala sahip iken, AVIRIS sistemi 224 spektral

kanala sahiptir. Elektro-optik sistemlerde dijital bir görüntüyü oluşturan piksel ağı algılayıcı platformunun hareketine dik ve aynı yönlü tarama hareketiyle kombine olarak elde edilir [32].

Çözünürlük kavramı, uzaktan algılanmış görüntü verilerinin yorumlama ve sınıflandırma doğruluklarını önemli derecede etkileyen bir faktördür [49], [50]. Genel olarak uzaysal, spektral, radyometrik ve zamansal olmak üzere dört tip çözünürlük vardır [51].

3.1.1. Uzaysal Çözünürlük

Uzaysal çözünürlük bağımsız olarak ayırt edilebilen veya ölçülebilen minimum obje büyüklüğüdür. Uydu algılama sistemlerinde açısal bir büyüklük olan anlık görüş alanı (IFOV, Instantaneous Field Of View) değeriyle ölçülür. Fotoğrafik sistemlerde ise film üzerinde çözülebilen milimetredeki çizgi sayısı ile ifade edilir. Uzaysal çözünürlük daha çok bir pikselin yeryüzünde karşılık geldiği alanla gösterilmesine karşın, kullanıcı amaçlarına bağlı olarak değişik yollarla da ölçülebilir. Temel olarak dört farklı kriter kullanılmaktadır [52]:

- 1- Görüntüleme sisteminin geometrik özellikleri
- 2- Nokta hedefler arasındaki ayırt etme kabiliyeti
- 3- Tekrarlı hedeflerin periyodikliğini ölçebilme kabiliyeti
- 4- Küçük hedeflerin spektral özelliklerini ölçebilme kabiliyeti


Geometrik özelliklere göre; yer yüzünde piksellere karşılık gelen alanlar arasındaki uzaklık yer örnekleme aralığı olarak adlandırılır (Ground Sample Interval-GSI). Algılayıcı sistemler, örnekleme aralığının (GSI) anlık yeryüzü görme alanına (Ground Instantaneous Field Of View-GIFOV) eşit alınmasıyla dizayn edilir. Örnekleme aralığı;

$$GSI = w \frac{H}{f} \quad (3.1)$$

dır. Burada f , odak uzaklığı ve H algılama sisteminin yeryüzünden olan yüksekliğidir. w parametresi ise detektörler arası uzaklık yani detektörlerin büyüklüğüdür. IFOV eşitliği;

$$IFOV = 2a \tan\left(\frac{w}{2f}\right) \approx \frac{w}{f} \quad (3.2)$$

ile gösterilir. IFOV parametresi, GIFOV'un açısal karşılığıdır. Şekil 3.3'de tek bir detektör elemanı için olan basit geometrik özellikler gösterilmektedir. Bütün elemanların sabit olduğu kabul edilmiştir. Gerçekte detektörlerin çalışma anında GIFOV hareket etmekte olup, bu da gösterildiğinden biraz daha büyük bir alanın projeksiyonuna neden olmaktadır.



Şekil 3.3: Optik bir sensördeki tek bir detektörün basitleştirilmiş geometrisi.

IFOV parametresi, algılayıcının çalıştığı H yüksekliğinden bağımsızdır. Hem görüntü uzayında hem de cisim uzayında aynı ve tek anlamlıdır. GIFOV parametresi;

$$GIFOV = 2H \tan\left(\frac{IFOV}{2}\right) = w \frac{H}{f} \quad (3.3)$$

eşitliğiyle gösterilir. IFOV, sistem dizaynında, GIFOV ise elde edilen görüntülerin analizinde göz önüne alınır. Yörünge yüksekliği sürekli değiştiği için hiçbir uydunun mükemmel sabit bir yörüngesi yoktur. Bunun sonucunda GIFOV düşük yüksekliklerde azalırken büyük yüksekliklerde artmaktadır. Örneğin LANDSAT 1-3 için yükseklik değeri 880-940 km aralığında bir değişim gösterir ve tek anlamlılık için nominal yükseklik 913 km alınır.

3.1.2. Spektral Çözünürlük

Spektral çözünürlük, algılayıcı sistemlerdeki spektral kanalların genişliğini ve sayısını ifade eder [50]. Her bir spektral kanalda ölçülen toplam enerji, bu kanal üzerine gelen birim ışınlılığın spektral ağırlıklı toplamıdır. b kanalına gelen (x,y) konumundaki sinyal;

$$s_b(x, y) = \int_{\lambda_{\min}}^{\lambda_{\max}} R_b(\lambda) E_{\lambda}^i(x, y) d\lambda \quad (W - m^{-2}) \quad (3.4)$$

ile ifade edilir. Buradaki $\lambda_{\min}$ ve $\lambda_{\max}$ kanaldaki duyarlılık aralığını belirler. E birim ışınlılık ve R parametresi de detektörün spektral duyarlılığıyla spektral filtre geçirgenliğinin bileşimini açıklar. Bu eşitlik algılanan ışınlılıkla daha sonra bu ışınlılığın detektör akımına dönüşümünün entegrasyonunu ifade eder [53]. Dalga boyu ile yapılan bu ağırlıklandırma algılayıcının spektral sinyaldeki detayları çözebilme kabiliyetinin başlıca belirleyicisidir. Elektromanyetik spektrumdaki konum, genişlik ve spektral kanalların sayısı çok spektrumlu görüntüde hedeflerin ayırt edilebilme derecesini belirler.

Yüksek spektral çözünürlük, algılayıcı çıkışı sinyal-gürültü (S/N) oranını azaltır. Sinyal, algılanan verinin bilgi içeriğidir ve gürültü ise sinyaldeki istenmeyen değişimlerdir. Böyle bir gürültü, sistematik veya rastlantısal olabilir ve algılayıcının mekanik veya elektronik parçalarının çalışmasındaki problemlerden kaynaklanabilir. S/N oranının olabildiğince yüksek olması istenir. Spektral kanalların dizilişi ve

yerleştirilmesi, algılayıcının spektral özellikleri ayırt edebilme kabiliyeti için spektral kanal genişlikleri kadar önemlidir.

3.1.3. Radyometrik Çözünürlük

Radyometrik çözünürlük veya duyarlılık, algılayıcı tarafından algılanan verilerin gösterilmesi, depolanması ve oluşturulması için gerekli dijital sayıları gösterir. Genel olarak, daha çok sayıda seviye olması bilginin daha detaylı elde edilmesini sağlamaktadır. Seviye sayısı, maksimum seviyedeki değerin kayıt edilmesi için gerekli sayısal dijitlerin (bit) sayısı ile gösterilir. Örneğin 8 bit/piksel çözünürlüğündeki bir sistem için 2^8 (256) farklı seviyede bilgi kaydedilebilir. Sistemin radyometrik çözünürlüğünün artırılması için S/N oranının dikkate alınması gerekir. Bir ışınlılık seviyesinin diğer komşu seviye ile arasındaki fark, gürültüden küçük olmamalıdır. Aksi takdirde seviyedeki değişimlerin, hedefin ışınlılığındaki değişimlerden kaynaklanıp kaynaklanmadığı anlaşılamaz.


3.1.4. Zamansal Çözünürlük

Yaklaşık kutupsal yörüngeli uzaktan algılama uydu sistemlerinin sağladığı en önemli avantajlardan biri aynı alanın periyodik olarak tekrar tekrar algılanmasıdır. Güneşe senkronize olan birçok uydu sistemi (LANDSAT, SPOT, NOAA AVHRR vb.) herhangi bir bölgeyi aynı lokal güneş zamanında algılamaktadır. Algılama periyodu, sadece sabit bir gözleme doğrultusuna (nadir gibi) sahip olan algılayıcılar için belirli uydu yörünge özelliklerine bağlıdır. Yörüngede birden fazla sistem varsa zamansal çözünürlük artırılabilir.

Periyodik algılamalar zamana bağlı değişim saptama analizleri ve tarım ürünlerinin görüntülenmesi için önemlidir. Gerçekte, zamansal özellikler farklı coğrafi bölgelerdeki belirli ürün tipleri için belirlenebilir ve çok zamanlı görüntülerin sınıflandırılması için kullanılabilir. Birkaç deneysel SAR uydusu ile uzay mekiği gibi insanlı uydu sistemleri kutupsal olmayan yörüngeye sahip olup, daha düşük bir algılama periyoduna sahiptir.

3.2. LANDSAT Uydu Sistemi

LANDSAT uydu sistemi dünya etrafında yaklaşık kutupsal bir yörüngede dönen uydularla bu uydularda var olan algılayıcılar tarafından elde edilen verilerin alındığı ve değerlendirildiği yer istasyonlarının oluşturduğu sistemdir. Amerika Birleşik Devletleri'ne ait olan sistem Temmuz 1972'de ilk LANDSAT uydusunun fırlatılmasıyla başlatılmıştır. Şekil 3.4'de, LANDSAT uydu sistemlerinin fırlatılma ve kullanımdan kalkma tarihleri gösterilmektedir. Son olarak Nisan 1999'da LANDSAT 7 fırlatılmış olup, Ekim 1993'de fırlatılan LANDSAT 6 uydusu yörüngeye oturtulamamıştır. Halen LANDSAT 5 ve 7 uyduları aktiftir. LANDSAT 5 veri saklama ünitesindeki arıza nedeniyle sadece eş zamanlı bağlantıyla veri gönderebilmektedir. MSS sisteminin kullanımı ise 1992 yılında sona erdirilmiştir.



Şekil 3.4: LANDSAT uydu sistemlerinin kullanım zamanları.

TM algılayıcıları spektrumun görünür, yansıyan kızılötesi, orta kızılötesi ve ısıal kızılötesi bölgelerinden yansıyan ya da yayılan enerjiyi saptar ve algılanan elektromanyetik ışınım 7 kanalda kaydedilir: TM sisteminin uzaysal çözünürlüğü sadece ısıal kanalı (120 m) hariç diğer kanallarda 30 m'lik bir çözünürlüğe sahiptir. Radyometrik çözünürlüğü 8 bittir. ısıal kanal hariç diğer kanallarda 16 detektörden oluşan bir dizi kullanılır. Sadece ısıal kanalda (6. kanal) 4 tane detektör kullanılmaktadır.

LANDSAT uydu ve algılayıcı sistem özellikleri Tablo 3.1 ve Tablo 3.2’de verilmiştir [54]. LANDSAT 7 uydusunda bulunan ETM+ algılayıcısına TM’de bulunan kanallara ek olarak 15 m uzaysal çözünürlüklü bir pankromatik kanal eklenmiştir. Ayrıca ısıl kanalın uzaysal çözünürlüğü de 60 m’ye artırılmıştır. Sistemin radyometrik çözünürlüğü, 9 bitlik orijinal tarama verisinin en iyi 8 bitlik kısmının seçilmesiyle oluşturulmaktadır. Uydu platformunda bağımsız üç tane kalibrasyon sistemi bulunmaktadır. Bu sistemlerle pankromatik, görünür, yakın kızılötesi ve kısa dalga kızılötesi kanallarının kalibrasyonu yapılmaktadır. ETM+ sisteminin mutlak radyometrik doğruluğu %5 ve rölatif doğruluğu da %2 düzeyindedir.

Tablo 3.1: LANDSAT 1-5 uyduları ve algılayıcı sistem özellikleri.

Algılayıcı ^{a/}	LANDSAT Platform	Spektral Kanallar (μm)		Uzaysal Çözme (m)	Yükseklik (km)	Tarama Genişliği (km)	Zamansal Çözme (gün)
RBV	1,2,3	PAN	0.505-0.750	79x59 ^{d/} 30x30 ^{e/}	920	185	18
		1 ^{b/}	0.475-0.575				
		2 ^{c/}	0.580-0.680				
		3 ^{c/}	0.690-0.830				
MSS	1,2,3,4,5	4 (yeşil)	0.5-0.6 ^{f/}	79x57 ^{e/} 60x60 ^{h/} 237x237 ^{i/}	920 ^{e/} 705 ^{h/}	185	18 ^{e/} 16 ^{h/}
		5 (kırmızı)	0.6-0.7				
		6 (NIR)	0.7-0.8				
		7 (NIR)	0.8-1.1				
		8 (Isıl)	10.4-12.6 ^{j/}				
TM	4,5	1	0.45-0.52	28.5x28.5 ^{k/} 120x120 ^{i/}	705	185	16
		2	0.52-0.60				
		3	0.63-0.69				
		4	0.76-0.90				
		5	1.55-1.75				
		6	10.40-12.50 ^{j/}				
		7	2.08-2.35				

^{a/} RVB, Dönen Işık Vidikon; MSS, Çok Spektrumlu Tarayıcı; TM, Tematik Algılayıcı

^{b/} Sadece Pankromatik ve LANDSAT 3

^{c/} LANDSAT 1 ve 2’deki kanal 1,2,3

^{d/} LANDSAT 1 ve 2

^{e/} LANDSAT 3

^{f/} Aynı zamanda LANDSAT 4 and 5’deki 1-4 kanalları

^{g/} LANDSAT 1-3

^{h/} LANDSAT 4 ve 5

^{i/} LANDSAT 3’deki kanal 8

^{j/} Isıl

^{k/} Kanallar 1-5 ve 7

^{l/} Sadece kanal 6

Tablo 3.2: LANDSAT 7 uydusu algılayıcı sistem özellikleri.

Algılayıcı ^{a/}	LANDSAT Platform	Spektral Kanallar (μm)		Uzaysal Çözme (m)	Yükseklik (km)	Tarama Genişliği (km)	Zamansal Çözme (gün)
ETM+	7	1	0.450-0.515	30	705	185	16
		2	0.525-0.605				
		3	0.630-0.690				
		4	0.750-0.900				
		5	1.550-1.750				
		7	2.080-2.350				
		6	10.40-12.50	60			
		PAN	0.520-0.900	15			

ETM+, Zenginleştirilmiş Tematik Algılayıcı; NIR, Yakın kızılötesi.

4. DİJİTAL GÖRÜNTÜ VE SINIFLANDIRMA TEKNİKLERİ

Dijital görüntü işleme teknikleri 1970'lerden başlayarak günümüze kadar büyük bir hızla gelişme göstermiştir. Özellikle uzaktan algılama, yarı-otomatik araç yönlendirme, iki ve üç boyutlu medikal görüntüleme ve otomatik gözlem vb., alanlarda büyük aşamalar kaydedilmiştir [55]. Günümüzde geliştirilen dijital görüntü işleme teknikleriyle uzaktan algılanmış dijital görüntülerin bir harita projeksiyonuna dönüştürülmesi, zenginleştirilmesi, sınıflandırılması ve değişim saptama gibi özel amaçlı analizlere uygulanması rutin hale gelmiştir.

İstatistiksel patern tanıma yöntemlerini kullanan bir çok dijital görüntü işleme teknikleri, piksellerin ton ve renk özelliklerini baz almaktadır [56]. Spektral veriden sentezlenen doku gibi değişik tekniklerde görüntülerin analizinde kullanılmaktadır. Ayrıca bilgisayarların insana benzer bir şekilde görüntüleri analiz edebilmeleri için algoritmalar geliştiren uzman sistemlerin yanısıra, gerçek dünyada var olan belirsizliği dikkate alan Bulanık Küme mantığını ve hiçbir dağılım kabulünü gerektirmeyen YSA tekniklerini baz alan yöntemlerde geliştirilmiştir [57], [58].


Gerçek üç boyutlu uzayın iki boyutlu görüntü formatına indirgenmesi sırasında bazı özellik kayıpları oluşur. Bu kayıplar, kontrast azalması, geometrik distorsiyonlar veya algılama sisteminden kaynaklanan gürültüler olabilir. Dijital görüntü işlemede amaç, insanların kullanabilmesi veya makine destekli analizler için görüntünün bu özellik kayıplarından arındırılması ve zenginleştirilmesidir [60].

Dijital görüntü işleme, görüntülerin algılanması, iletimi, işlenmesi ve sunulması işlemlerini içerir [61]. Görüntü işleme tekniklerinin amacı, görüntülerin görsel yorumlanabilirliğini geliştirmek ve en temel olarak görüntüsel bilgiyi bilgisayar ortamında işlemektir. Bu teknikler görüntü rektifikasyonu ve onarımı, görüntü zenginleştirme ve sınıflandırma olarak üç ana gruba ayrılabilir [59].

4.1. Dijital Görüntü


Görüntü, üç boyutlu gerçek fiziksel uzayın iki boyutlu bir gösterimidir [60]. İnsan görme sistemi bir görüntü girdisini uzaysal olarak dağılmış ışık enerjisinin toplamı olarak algılar. Bu şekildeki algılama optik görüntü olarak adlandırılır.

Alışlagelen analog fotoğraflar, sürekli bir $F(x,y)$ fonksiyonu ile ifade edilebilmektedir. $F(x,y)$ fonksiyonunun değeri, x,y uzaysal değişkenlerle belirtilen konumdaki genliği (yoğunluğu) ifade eder. Eğer böyle sürekli bir fonksiyona sahip analog bir görüntü hem uzaysal değişkenlere hem de genliğe göre ayrık hale getirilirse sonuçta oluşan ayrık $f(x,y)$ fonksiyonu dijital bir görüntü olarak adlandırılır. Uzaysal değişkenlerin ayrıklaştırılması örnekleme ve genliğin ayrıklaştırılması kuantalama olarak adlandırılır. Örnekleme sürekli görüntü fonksiyonundan (parlaklık) dijital eşdeğerine belirli noktalarda yapılan bir geçiştir. Bu örnekleme noktalarının düzlemde sıralanmasıyla oluşan geometrik ilişki grid olarak tanımlanır. Grid içinde artık bölünemeyen sonlu küçük bir örnekleme noktası piksel olarak adlandırılan bir resim elemanına karşılık gelir. Üzerindeki noktalar arasında bir komşuluk ilişkisi tanımlanan grid, raster olarak tanımlanır. Böylece örnekleme işlemiyle dijital bir görüntünün en küçük birimi olan pikseller elde edilirken kuantalama işlemiyle gri yoğunluk değerleri elde edilmektedir. Şekil 4.1’de dijital bir görüntünün koordinat sistemi gösterilmektedir [61].



Şekil 4.1: Dijital görüntü koordinat sistemi (satır-sütun).

Gri yoğunluk değerleri, parlaklığın belirli sınırlar arasına çekilmiş ölçüsüdür. Gri yoğunluk değerleri sıfır ile 2^8-1 değeri arasında tanımlanır. Uygulamada genellikle g değeri 0 ile 10 arasında bir değer söz konusu olmakla beraber bu değer, uzaktan algılanmış dijital görüntüler için genellikle 8'dir. Sistemin radyometrik çözünürlüğünü de belirleyen bu değer 8 olmasıyla gri yoğunluk değerleri 0-255 arasında toplam 256 seviye ile tanımlanır. Uygulamada piksel formları çoğunlukla kare veya altıgendir (Şekil 4.2) [55]:



Şekil 4.2: (a) Kare yapılı grid, (b) altıgen grid.

Elde edilen bu uzaysal değişkenler ve parlaklık seviyeleri genellikle tam sayı değerlerdir. Sonuç olarak dijital bir görüntü, elemanları, uzaydaki x,y konumlarına karşılık gelen noktaların $f(x,y)$ parlaklık (ışık yoğunluğu) değerlerini içeren bir matristir. Genel olarak dijital görüntüler; 1- Binari, 2- Gri, 3- Renkli ve 4- Çok spektrumlu olarak sınıflandırılmaktadır.

1- Binari görüntüler en basit tipteki görüntülerdir. Sadece 2 değer alırlar: 0 veya 1. Tipik olarak siyah-beyaz bir görüntü oluşur.

2- Gri seviyeli görüntüler, monokrom veya tek renkli görüntülerdir. Renk bilgisi içermeyip sadece parlaklık bilgisi içerir.

3- Renkli görüntülerde renk, nesnelerin farklı dalga uzunluğuna sahip elektromanyetik dalgaları farklı yansıtma özellikleri (parlaklık değeri) ile ilişkilidir. Tipik renkli görüntüler kırmızı, yeşil ve mavi (RGB) görüntü olarak adlandırılır. Verinin her bir kanalı farklı bir renge karşılık gelir [62].

4- Çok spektrumlu görüntüler normal insan algılama spektrumu dışındaki bölgelerde de bilgi içeren görüntülerdir. Örneğin x-ışınları, kızılötesi ışınlar gibi. Bu tür verilerin kaynağı, uydu sistemleri, su altı algılama sistemleri, değişik tipteki uçak radarları, kızılötesi görüntüleme sistemleri ve tıbbi tanı görüntüleme sistemleridir.

4.2. Görüntü Karakteristikleri

4.2.1. Histogram ve Kümülatif Histogram

Görüntü histogramı, her bir parlaklık değerinde bulunan piksel sayısı ile görüntü piksellerinin istatistiksel dağılımını açıklamaktadır. Basit olarak, frekansı yani her bir parlaklık seviyesindeki (DN) piksel sayısının toplam görüntü piksel sayısına oranını gösterir. Histogram formülü;

$$hist_{DN} = A \cdot det(DN) / N \quad (4.1)$$

ile verilmektedir. Burada N, toplam görüntü piksel sayısıdır. Bu ifade bazen olasılık yoğunluk fonksiyonuyla eş anlamlı kullanılabilir. Bu ise;

$$hist_{DN} \approx PDF(DN) \quad (4.2)$$

yaklaşık eşitliği ile ifade edilebilir. Bu kullanım matematiksel olarak problem yaratabilmektedir. Çünkü, (i) PDF, sürekli değişkenler için tanımlıdır, (ii) PDF sadece tesadüfi bir işlemden doğan istatistiksel dağılımlar için kullanılmaktadır. Buna karşın, dijital görüntüler (i) süreksiz ve ayrıktır ve (ii) görüntüler nadiren tesadüfi bir işlem sonucu gibi davranır. Daha çok, bireysel veri dizileridir. Bu nedenle uzaktan algılamada dijital görüntüler için histogram kullanımı daha uygundur. Histogramlar verinin uzaysal dağılımı hakkında herhangi bir bilgi içermez [30].

Kümülatif histogram, histogram eşitleme, çakıştırma ve hatalı piksellerin giderilmesi gibi görüntü zenginleştirme teknikleri için hesaplanır [63]. Kümülatif histogram;

$$chist_{DN} = \sum_{DN=DN_{\min}}^{DN_{\max}} hist_{DN} \quad (4.3)$$

monotonik bir fonksiyondur. Normalize edildiğinde asimptotik maksimumu birdir ve kümülatif yoğunluk fonksiyonu olarak adlandırılır [64]. Ancak histogramın sahip olduğu benzer kısıtlamalara sahiptir.

4.2.2. İstatistiksel Parametreler

Görüntü ortalama değeri:

$$\mu = \frac{1}{N} \sum_{p=1}^N DN_p \text{ veya } \sum_{DN=DN_{\min}}^{DN_{\max}} DN * hist_{DN} \quad (4.4)$$

ile bulunur. İkinci eşitlik, her bir DN değerini karşılık geldiği histogram değeriyle ağırlıklandırır ve ağırlıklı DN değerlerini toplar. Bu form, histogramın birinci momenti olarak adlandırılır. Ortalama değer, tüm görüntü için genel parlaklığı yansıtır.

Verinin ortalama değer etrafındaki yayılımını anlamak için kullanılan varyans eşitliği:

$$\sigma^2 = \frac{1}{N-1} \sum_{p=1}^N (DN_p - \mu)^2 \text{ veya } \frac{N}{N-1} \sum_{DN=DN_{\min}}^{DN_{\max}} (DN_p - \mu)^2 * hist_{DN} \quad (4.5)$$

ile verilir. Görüldüğü gibi veri kümesindeki her bir elemanla verinin ortalaması arasındaki farkların karesinin ortalaması alınmaktadır [65]. Standart sapma (σ), varyansın kareköküne eşittir ve varyansın orijinal birime geri döndürülmesi ve orijinal değerlerle ilişkilendirilebilmesi için kullanılır [65]. Ayrıca bu değer, verinin ortalama değerden tam olarak ne kadar saptığını da göstermektedir. İkinci eşitlik histogramın ikinci momentidir. Ortalama değer, öncül bilinen bir dağılım yerine veri kümesinin kendisinden belirleniyorsa N yerine N-1 kullanılır [66]. Standart sapma histogram genişliğini de (ortalama değer etrafındaki yayılma) gösterdiği için görüntü kontrastının bir ölçüsü olarak da kullanılmaktadır, örn., küçük standart sapma değeri, düşük kontrastlı düz bir görüntüyü belirtir. Ayrıca ortalama ve standart sapma değerleri Gauss Normal Dağılımının tanımlanması için yeterli parametrelerdir [67].

Mod, histogramın maksimum olduğu DN değeridir.

Medyan, histogramı alanları eşit iki parçaya bölen DN değeridir. Toplam piksellerin %50 si bu değer altında ve %50 side bu değer üstündedir.

Kovaryans, iki değişkenin karşılıklı ortalama değerleri çevresinde oluşturdukları çarpım momentidir. Eğer iki değişken aynıysa ortaya çıkan değer varyans olur. m ve

n değişkenleri arasındaki (örneğin çok spektrumlu bir görüntünün iki kanalı) kovaryans değeri;

$$\sigma_{mn} = \frac{1}{N-1} \sum (DN_{pm} - \mu_m)(DN_{pn} - \mu_n) \quad (4.6)$$

ile ifade edilir. Çok spektrumlu bir görüntüde kovaryans, aynı pikselin farklı kanallardaki DN değerlerinin birbirleriyle olan korelasyonlarını inceler. Varyans farkların karelerinin ortalamasını belirtirken, kovaryans farkların çarpımlarının ortalamasını belirtir. Toplam p değişken için kovaryans matrisi C;

$$C = \begin{bmatrix} \sigma_{11} & \sigma_{12} & \cdots & \sigma_{1p} \\ \sigma_{21} & \sigma_{22} & \cdots & \sigma_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{p1} & \sigma_{p2} & \cdots & \sigma_{pp} \end{bmatrix} \quad (4.7)$$

ile gösterilir. Dispersiyon veya varyans-kovaryans matrisi olarak da bilinen kovaryans matrisi pozitif yarı-tanımlı simetrik bir matristir, yani, veri kümesindeki bütün değerler için sıfırdan büyük değerler alırlar ($f(x) \geq 0, \forall x$ için). Matrisinin köşegenleri varyans değerleridir [68].

İki değişken arasındaki lineer karakterli istatistiksel ilişkiyi birimden bağımsız olarak yorumlayabilmek için kovaryans katsayıları ilgili değişkenlerin standart sapmalarının çarpımıyla bölünerek normalize edilirler. Bu işlem sonucu elde edilen değer korelasyon katsayısıdır:

$$\rho_{mn} = \frac{\sigma_{mn}}{\sqrt{\sigma_{mm}} \sqrt{\sigma_{nn}}} \quad (4.8)$$

Korelasyon katsayısı iki değişken arasındaki lineer ortaklığı gösterir. Toplam p değişken için korelasyon matrisi;

$$R = \begin{bmatrix} 1 & \dots & \rho_{1K} \\ \vdots & \ddots & \vdots \\ \rho_{K1} & \dots & 1 \end{bmatrix}, \quad -1 \leq \rho_{mn} \leq 1 \quad \text{veya} \quad |\rho_{mn}| \leq 1 \quad (4.9)$$

dir. ρ_{mn} 'in +1 veya -1'e yaklaşması lineer bağımlılığın kuvvetini artırırken, 0'a yaklaşması azaltır. Korelasyon, birbirinden bağımsız iki değişken için sıfır ve birbiriyle aynı olan değişkenler için birdir. Negatif değerler ilişkinin ters yönlü olduğunu gösterir. Örneğin bir görüntünün kendi negatifiyle olan korelasyonu eksi birdir. Değişkenler arasındaki ilişki lineer değilse, korelasyon ayırt edici istatistiksel bir özellik olamaz [68].

4.3. Dijital Görüntü Sınıflandırması

Sınıflandırma veya patern tanıma, görüntüdeki anlamlı patern gruplarının belirlenmesi işlemidir [69]. Sınıflandırma işlemiyle görüntüde bulunan farklı özelliklerin veya objelerin belirlenmesi ve tanımlanması görevini yerine getirecek kantitatif karar fonksiyonları oluşturulur. Spektral tabanlı sınıflandırmada, kantitatif karar fonksiyonları piksellerin spektral yansıtım değerleri baz alınarak belirlenirken, uzaysal sınıflandırmada görüntüdeki objelerin geometrik şekilleri, büyüklükleri ve topolojik ilişkileri gibi uzaysal özellikleri baz alınır [70].

Yeryüzünün uzaktan algılanmış görüntü verileri ile değişik amaçlara yönelik tematik bilgiler elde edilebilmektedir. Bu amaçla uygulanan sınıflandırma işleminde veri bilgiye dönüştürülür [71]. Sınıflandırma sonucu oluşturulan tematik bir harita, tanımlanabilir yeryüzü özelliklerinin uzaysal dağılımını gösterir. Verilen bir alan üzerinde verinin tanımlanmasından daha çok bilgisel bir gösterim sağlar. Gösterilecek olan temalar, toprak, bitki örtüsü türleri ve su gibi genel arazi örtüsü sınıflarına ek olarak yerleşim, sanayi ve park alanları gibi arazi kullanım sınıflarını içermektedir. Uzaktan algılanmış görüntülerde bu sınıflara ait spektral özellikler arasındaki karışım nedeniyle birbirlerinden ayırt edilebilirliği etkileyen başlıca dört faktör vardır [30]:

- 1- Topoğrafya ve topoğrafik aydınlanma şartları,
- 2- Atmosferik değişkenlik,

3- Algılayıcı kalibrasyon değişimleri,

4- Bir piksel alanı (GIFOV) içindeki sınıf karışımları.

Sınıflandırma işlemi temel olarak aşağıdaki aşamaları içermektedir:

1- Özellik çıkartımı: Bu aşamada çok spektrumlu görüntü verisi uzaysal veya spektral dönüşümlerle farklı bir özellik uzayına dönüştürülür. Örneğin, optimum sınıflandırma performansını verecek alt kanal gruplarının seçimi ve kanallar arası korelasyonu ortadan kaldıracak ana-bileşen (PC) dönüşümü gibi.

2- Eğitim aşaması: Bu aşama kontrollü ve kontrolsüz olarak iki şekilde yapılır. Kontrollü sınıflandırmada, görüntü üzerinde önceden belirlenen kategorileri temsil edecek ve paternleri birbirinden ayırt edecek karar fonksiyonlarının elde edileceği örnek eğitim paternleri kullanılmaktadır. Kontrolsüz sınıflandırmada ise herhangi bir temsil edici eğitim veri kümesi olmaksızın veri kendi doğal spektral gruplarına ayrılır. Patern, sınıflandırma işleminin esas alınacağı görüntü özelliklerine ait ölçüm vektörüdür. Spektral tabanlı sınıflandırma problemlerinde paternler görüntü verisinin her bir spektral kanaldaki ışınlılığın ölçüm değerleridir. Uzaysal tabanlı sınıflandırma problemlerinde ise patern, görüntüdeki elemanların (piksel) komşuluk, geometrik yakınlık, doku gibi uzaysal ölçütleridir [72], [70]. Örneğin 7 kanallı LANDSAT TM görüntüsündeki herhangi bir X paterni, ilgili pikselin her bir kanalda sahip olduğu yansıtım değerlerini içeren;

$$X = [DN_1 \quad DN_2 \quad DN_3 \quad DN_4 \quad DN_5 \quad DN_6 \quad DN_7]^T \quad (4.10)$$

vektörüyle gösterilir. Sınıflandırmanın her aşamasında paternleri en iyi açıklayan özellik değerlerinin ve paternlerin hangi kategorilere dahil edileceğine karar veren uygun bir karar mekanizmasının belirlenmesi gereklidir.

3- Etiketleme: Kontrollü piksel sınıflandırmasında eğitim verileriyle belirlenen karar fonksiyonlarıyla özellik uzayını oluşturan her bir patern bilinen bir sınıfa atanır. Kontrolsüz sınıflandırmada ise görüntü verisinin sahip olduğu doğal spektral grupların oluşturduğu kümeler, daha sonra arazi incelemeleriyle veya topoğrafik haritalar ve hava fotoğrafları kullanılarak etiketlenir. Sonuç ürün her bir piksel için tek bir kategori içerir. Karışık piksel sınıflandırma yönteminde, sınıfların ayırt edici

özelliklerinin birbiriyle karışmış oldukları kabul edilip, her bir pikselin ilgili sınıflara olan üyelik dereceleri belirlenir.

Bütün sınıflandırma işleminde amaç, dijital görüntü verisini farklı yüzey materyallerini ve durumlarını kategorize eden açıklayıcı etiketlere dönüştürmektir. Çok spektrumlu görüntülerin (birkaç taneden yüzlerce kanala kadar) kategori etiketlerini içeren bir haritaya indirgenmesiyle orijinal veri miktarında önemli derecede bir azalma olur. Bu nedenle sınıflandırma işlemi bazı durumlarda veri sıkıştırma aracı olarak da kullanılabilmektedir [30].

Birçok görüntü işleme algoritması piksel gruplarını veya pikseller arasındaki benzerlikleri esas alır. Burada önemli olan nokta; bir kategoriye diğerinden ayıran fiziksel sınıf karakteristiklerine karşılık gelen sınıf veri özelliklerinin nasıl belirleneceğidir. Örneğin arazi kullanım haritalarının hazırlanmasında konuma bağlı olarak pikselden piksele meydana gelecek spektral değişimlerle bu tip bir analizi istenen doğrulukla gerçekleştirmek mümkün olmayabilir. Bunun için daha kompleks fiziksel ölçmelere ihtiyaç duyulur. Yardımcı veri olarak adlandırılan bu veriler arazi eğimleri, yüzey yükseklikleri veya doku bilgisi gibi ek bilgilerdir.


Çok spektrumlu bir görüntünün yüksek doğrulukla sınıflandırılması, sınıfların ayırt edici özellikleri arasındaki karışım oranına bağlıdır. Bu oranın dikkate alınmasına göre optimum yöntemler geliştirilebilir.

4.3.1. Piksel Bazlı Sınıflandırma

Genel bilim literatüründe kullanılan tematik harita anlayışı, arazideki her bir noktanın sadece tek bir kategoriye ait olması anlayışına dayanır. Bu yaklaşım, kolay uygulanabilir olmasına rağmen, gerçek çevre şartlarına ve uzaktan algılama verisinin dijital karakterine uygun değildir. Bir çok sınıflandırma algoritması herhangi bir sınıf değerinin bir piksele atanması için belirli bir benzerlik fonksiyonu üretir. Piksel sınıflandırmasında, bilinmeyen piksele bu pikselin en büyük benzerlik değerine sahip olduğu sınıf etiketi atanır (“Kazanan Hepsini Alır” yaklaşımı). Böyle bir sınıflandırma için özellik uzayı karar sınırları rijit olarak tanımlanır [30].


Alt-piksel sınıflandırmasında ise her bir pikselin birden fazla sınıfa olan benzerlik değerleri elde edilebilir. Pikseller bu benzerlik değerlerine göre belirli üyelik

oranlarıyla birden fazla sınıfa atanır. Böyle bir sınıflandırma için özellik uzayı karar sınırları bulanık yapıdadır. Benzerlik değerleri uzaysal ve spektral olarak bütünleşik olan paternlere (piksel özellik vektörü) atanan her bir kategorinin ilgili patern içindeki rölatif bulunma oranlarını gösterir. Şekil 4.3’de özellik uzayında oluşan karar sınırları ve eğitim verisinin dağılımı gösterilmektedir [46].



Şekil 4.3: Özellik uzayında oluşan karar sınırları içinde eğitim verisi için olası iki durum.

Eğer ayırım derecesi yüksekse hatasız sınıflandırma işlemini yapabilecek birçok potansiyel karar sınırı kuralı vardır. Eğer sınıflar arası bindirme varsa hatasız kolay bir karar sınırı oluşturmak imkansızdır. Şekil 4.4’de alt piksel ve piksel sınıflandırma yöntemleri arasındaki temel fark grafik olarak verilmektedir [46].



Şekil 4.4: Alt piksel ve piksel sınıflandırma işlemleri arasındaki fark.

4.3.2. Alan Bazlı Sınıflandırma

Piksel bazlı sınıflandırmaya diğer bir alternatif de alan bazlı sınıflandırmadır. Bu yöntem görüntüdeki objelerin biçimsel sınırları hakkında apriori bilgiler gerektirir

(örneğin tarım alanları gibi). Eğer bu objelerin sınırları sayısallaştırılır ve görüntüye kayıtlı edilirse bu sınırlar içinde kalan piksellerin özellikleri kullanılarak bu alanlar karakterize edilebilir. Örneğin bir bölgedeki spektral özellikleri temsil etmek için kanallardaki ortalama ve standart sapma değerleri kullanılabilir. Bu yöntemde pikseller yerine alanlar sınıflandırılır. Sınırlar kenar çıkartım algoritmaları kullanılarak elde edilebilir. Alan bazlı sınıflandırma yöntemi, daha çok SAR görüntü verileri için kullanılmaktadır. Bunun nedeni, bireysel piksellerin sınıflandırma performansını olumsuz etkileyen bu görüntülere özgü, benek olarak adlandırılan bir gürültüye sahip olmasıdır [72].

4.3.3. Özellik Çıkartımı

Sınıflandırma işleminde çok spektrumlu görüntü verisi bütünüyle kullanılabilir. Fakat böyle bir bütünün içerisinde atmosferik saçılma ve topoğrafik rölyef gibi çeşitli dış etkiler vardır. Ayrıca algılayıcı sistemlerin spektral çözünürlüklerindeki artışa bağlı olarak artan kanal sayısından dolayı çok spektrumlu görüntü verileri, genellikle kantitatif analizlerin etkinliğini azaltan kanallar arası yüksek korelasyona sahiptir. Bu noktada özellik çıkartımın da amaç, işlenecek görüntü verisinin boyutsallığını, sahip olduğu bilginin büyük bir bölümünü koruyacak şekilde azaltmaktır. Uzaktan algılamada eğitim verisinin özellik seçimi istatistiksel ve/veya grafik olarak yapılabilir. Boyutsallığın azaltıldığı istatistiksel özellik seçiminde ana-bileşen analizine ek olarak, orijinal veriyi değiştirmeden mevcut spektral sınıflar için en iyi ayırt edilebilirlik potansiyeline sahip alt özellik kombinasyonlarını belirleyen Diverjans ve Bhattacharyya uzaklığı gibi analizler kullanılmaktadır.

Ana-bileşen (PC) dönüşümünün amacı, verinin değiştirilerek yeni bir dizilişle boyutsallığının azaltılmasıdır. Böyle bir uygulamada yapılabilecek temel işlem, ilk m sayıdaki ana-bileşenin, orijinal verinin bütün p boyutunun yerine kullanılmasıdır ($m \leq p$ dir). PC dönüşümüyle elde edilen bilgi doğrudan orijinal verinin saçılımı veya varyansı ile ilgili iken sınıflar arası farkların fonksiyonu değildir. Bunun sonucunda, PC dönüşümüyle oluşan ve kullanılmayan “ $p-m$ ” bileşenleri herhangi x ve y sınıf çiftini ayırt etmek için gerekebilecek bilgileri içerebileceğinden, PC analizinin dikkatli kullanılması gerekir [73].

Kontrollü sınıflandırmada, istenen karar sınırları eğitim verileriyle belirlendiği ve verinin doğal spektral kümeleşmesiyle oluşturulmadığı için sınıfların birbirlerinden ayırt edilebilir olmasının bir garantisi yoktur. Ayırt edilebilirlik analizi sınıflandırmadan beklenen hatanın irdelenmesinde de kullanılmaktadır [24]. Bu amaca yönelik olarak özellik seçiminde farklı gruplardan oluşturulan ikili elemanlar arasındaki farkın ölçüsünün türetilmesine dayanan diverjans analizi de uygulanmaktadır [74].

Diverjans analizi, uygulandığı verilerin çok değişkenli normal dağılıma uymasını gerektirir. Normal dağılımdan uzaklaştıkça analiz sonuçları da kötüleşecektir. Bu nedenle bu analizin veri dağılımından bağımsız sadece verinin kendisine bağlı olarak karar sınırlarını oluşturan YSA sınıflandırıcılardan ziyade istatistiksel sınıflandırıcılarla kullanılması daha uygundur [72]. Özellik boyutu p olan bir verinin m alt kümeleri için diverjans ölçüsünün hesabı aşağıdaki eşitlikle hesaplanır [75]:

$$J_{ij} = \frac{1}{2} \text{tr}[(v_i - v_j).(v_i^{-1} - v_j^{-1})] + \frac{1}{2} \text{tr}[(v_i^{-1} + v_j^{-1}).(m_i - m_j).(m_i - m_j)^T] \quad (4.11)$$

Burada tr işlemi, matrisin izi (diyagonal elemanlarının toplamı), v_i , v_j i ve j sınıflarının kovaryans matrisleri ve m_i , m_j ise i ve j sınıflarının ortalama değerleridir. Diverjans değeri, aynı sınıflar için sıfır olurken farklı sınıflar için ayırt edilebilirlik derecesine göre büyüyen değerler almaktadır. Diverjans analizinin asıl amacı sınıflandırma performansı için orijinal verideki p adet kanaldan en optimal olan alt-kanal kombinasyonlarını belirlemek olmasına rağmen, tüm kanalların kullanılması durumunda iki ayrı sınıfa ait eğitim veri kümelerinin birbirlerinden istatistiksel ayırt edilebilirlik derecesini belirlemek içinde kullanılabilir. Diverjans incelenen her iki sınıf içinde hem ortalama değerleri hem de kovaryans değerlerini kullandığı için sınıflar arası farklar frekans dağılımının şekli ve dağılım merkezinin konumu dikkate alınarak incelenir. Eğer ikiden fazla sınıf için diverjans değeri istenirse, bu durumda ortalama diverjans değeri belirli kanal kombinasyonu sabit tutularak olası sınıf çiftleri için hesaplanır [71]:

$$J_{ort} = \frac{\sum_{i=1}^{n-1} \sum_{j=i+1}^n J_{ij}}{C} \quad (4.12)$$

Burada C, toplam alt kanal kombinasyon sayısı ve m, toplam sınıf sayısıdır. Bu formüle göre en büyük ortalama diverjans değerini veren alt kanal kombinasyonu m kategorinin sınıflandırılması için seçilir. Fakat ortalama diverjans analizinin bir dezavantajı olarak, J_{ij} değerinin dağılımı bilinmemektedir ve kolaylıkla ayırt edilebilen merkezden uzak sınıflar ortalama diverjans değerini büyütecekleri için optimal olmayan alt kanal kümeleri yanlış bir şekilde en iyi olarak görünebileceklerdir [63]. Bu sakıncalı durumu ortadan kaldırmak için dönüştürülmüş diverjans değerinin hesaplanması gerekir:

$$TJ_{ij} = 2000 \left[1 - \exp\left(\frac{-J_{ij}}{8}\right) \right] \quad (4.13)$$

Elde edilecek 2000 değeri mükemmel, 2000-1700 arası iyi ve 1700'ün altındaki değerler zayıf ayırt edilebilirlik derecesini gösterirler [71].

Ayırt edilebilirlik için kullanılan diğer bir ölçüt ise Bhattacharyya uzaklığıdır. Bu ölçüt istatistiksel ayırt edilebilirlikten daha çok, doğru sınıflandırma olasılığını belirler [76]. Bhattacharyya uzaklığı;

$$B_{ij} = \frac{1}{8} (m_i - m_j)^T \frac{(v_i + v_j)}{2} (m_i - m_j) + \frac{1}{2} \ln \frac{\det \frac{v_i + v_j}{2}}{\sqrt{\det(v_i)} \cdot \sqrt{\det(v_j)}} \quad (4.14)$$

eşitliği ile ifade edilir. B mesafesi çok değişkenli normal dağılıma dayanmaktadır. Verilen p adet özelliğe sahip her bir çift sınıf için B mesafeleri hesaplanır ve bu mesafelerin $p(p-1)/2$ sınıf için olan toplamaları elde edilir. $p(p-1)/2$ sınıf içinde en iyi toplam değerini veren kombinasyon en yüksek ayırt edilebilirlik derecesine sahip olacaktır.

Bu istatistiksel yöntemlerle özellik seçiminde nümerik bir kriter oluşturulsa bile analiz edilen verinin spektral karakteristiğini tam olarak anlamak için verinin görselleştirilmesine ihtiyaç duyulur. Bu nedenle grafik teknikler özellik seçimi için

istatistiksel tekniklerle beraber etkin olarak kullanılmaktadır. Grafik teknikler olarak, bar-grafigi spektral çizimi, yardımcı spektral ortalama vektör çizimleri, özellik uzayı çizimleri ve özellik uzayında yardımcı spektral paralel kenar veya elips çizimleri mevcuttur. Sonuncu teknikte, iki boyutlu özellik uzaylarında oluşturulan spektral saçılım grafiği üzerine her bir sınıf, kendi ortalama ve standart sapma değerleri kullanılarak paralel kenar veya elips şeklinde çakıştırılarak çizilir [77], [78]. Böyle bir gösterimde görüntü verisinin herhangi iki kanalının oluşturduğu iki boyutlu özellik uzayındaki saçılım grafiği üzerine sınıf spektral verileri, ortalama değerlerine standart sapma değerleri eklenerek ve çıkarılarak belirlenen koordinatlar içinde dikdörtgen şekillerle gösterilebilir.

4.3.4. Eğitim

Bir görüntüyü istenen kategorilere ayırmak için sınıflandırma algoritmasının eğitilmesi gerekir. Bu amaçla kategorileri temsil eden eğitim örnekleri kullanılır. Sınıflandırma algoritması eğitim örnekleriyle temsil edilen farklı kategorileri tanımak için eğitildikten sonra eğitim sırasında oluşturulan karar sınırlarına göre görüntüdeki paternler sınıflandırılır. Sınıflandırma performansının olabildiğince gerçeği yansıtabilmesi için eğitim örneklerinin sınıfları temsil derecelerinin yüksek olması gerekmektedir. Eğitim verilerinin seçiminde coğrafi konumlar dikkate alınmalıdır. Eğitim verilerinin özelliklerine etki edecek toprak tiplerindeki farklar, su kirliliği, ürün çeşitleri, olağan olmayan toprak nem oranları, atmosferik pus gibi çevresel faktörlerin görüntüdeki konumları ve coğrafi dağılımlarına ek olarak eğitim örneklerinin uzaysal ve zamansal değişim özellikleri de dikkate alınmalıdır. Tek bir görüntü, bu görüntüden elde edilen eğitim verisi ayırt edici özelliklerine göre sınıflandırılacaksa atmosferik faktörler genellikle kritik değildir. Çünkü çoğunlukla bu faktörler görüntü içerisinde sabittir ve kategorisi belirlenecek piksellere ait spektral vektörlerin rölatif konumlarını etkilemez. Ama bu eğitim verisi özellikleri başka bir görüntünün sınıflandırılması için kullanılacaksa her iki görüntü de atmosferik şartlar için düzeltilmelidir [30]. Kontrollü sınıflandırma işleminin doğruluğu, (i) spektral sınıfların sayısının ve istatistiksel karakteristiklerinin temsil doğruluğuna, (ii) sınıflandırma tekniğinin dayandığı kabullerin gerçeğe ne kadar uyduğuna bağlıdır [72].

İstatistiksel ölçümlerin geçerliliği sınıf örnek verisinin büyüklüğüne ve temsil derecesine bağlıdır. Büyüklük, görüntüdeki kanal sayısına ve belirlenmesi gereken istatistiksel parametrelerin sayısına bağlıdır. Genel bir minimum değer olarak 10p veya 30p tercihen olması istenen eğitim verisi büyüklük değerleridir [71], [72]. Örneğin Maksimum Olabilirlik yöntemine göre sınıflandırmada gereken istatistiksel ölçütlerden biri olan kovaryans matrisinin belirlenebilmesi için eğitim veri kümesinin minimum patern sayısı $p+1$ olmalıdır. Artan örnek verisi büyüklüğüyle sınıflandırma doğruluğunun arttığı gösterilmiştir [79]. Bununla beraber küçük eğitim veri kümeleri için YSA sınıflandırıcıların istatistiksel sınıflandırıcılardan daha iyi sonuçlar verdiği gösterilmiştir [80], [81], [58].

Eğitim paternleri, genellikle arazi çalışmalarından, hava fotoğraflarından ve/veya harita yorumlarından ve görüntü üzerindeki konumlarından görsel olarak yorumlanarak seçilir. Eğitim verileri; (i) ağaç yüksekliği, kanopi kapalılık oranı ve göğüs yüksekliği çap mesafesi gibi verilere göre, (ii) görüntü üzerinde belirlenen poligonlarla, (iii) “seeding” yöntemiyle seçilebilir. “Seeding” yönteminde, (x,y)-konumunda seçilen pikselin karakteristik benzer komşuları belirli bir kritere göre araştırılır. Seçim alanı, orijinal çekirdek piksele karakteristik özdeş olan pikseller bulundukça görüntünün diğer bölgelerine doğru genişler [82].

Eğitim verilerinin güvenilirlik ve temsil dereceleri, uzaysal oto-korelasyon veya saf olmayan karışık piksellerin bulunma derecesine göre düşer. Uzaysal oto-korelasyon bir pikselin yakın komşu piksellerle arasındaki korelasyondur. Oto-korelasyonun bulunması eğitim veri kümesinden hesaplanan kovaryans matris değerlerinin küçülmesine, istatistiksel olarak taraflı olmasına ve böylece sınıflandırma doğruluğunun düşmesine neden olur. Bir eğitim veri kümesindeki piksellerin tesadüfi seçilmesiyle hesaplanan kovaryans matrisinin, aynı eğitim verisindeki bütün piksellerden blok olarak hesaplanan kovaryans matrisinden önemli ölçüde büyük olduğu görülmüştür [83]. Uzaysal oto-korelasyonun yüksek seviyede olmasının sınıflandırma doğruluğunu azalttığı belirtilmektedir [79]. Literatürde yapılan diğer bir çalışmada eğitim verisi için ideal piksel toplama yöntemi olarak, bölgedeki her n. veya başka bir kritere uygun olarak piksellerin rasgele toplanması önerilmektedir. [84].

Kontrolsüz eğitimde, heterojen piksel örneği içindeki özellik vektörlerinin toplamını yerleştiren bir algoritma kullanılır. Oluşan piksel kümeleri sınıfları temsil etmektedir. Gerçekte kontrollü ve kontrolsüz eğitim algoritmaları birbirini bütünleyen yöntemlerdir. Kontrollü eğitimde bilgi, sınıfları ve karakteristikleri zorlayarak elde edilirken kontrolsüz eğitimde algoritma, verinin yapısındaki mevcut olan doğal bilgiyi açığa çıkartır. Harici bir bilginin sınırlaması ve zorlaması olmaz. Sonuçta oluşan gruplar doğal spektral gruplardır. Küme terimi, çok spektrumlu veri uzayının lokalize edilmiş bir bölgesindeki piksel vektörlerinin ayrık gruplaşması anlamına gelir.

Kontrolsüz eğitim için görüntü alanlarının tanımlanmasında alanların homojenliği önemli değildir. İlgilenilen bütün sınıflar ve onların kendi sınıf içi değişkenliklerinin dikkate alınması için heterojen alanlar, kasıtlı olarak seçilir. Tanımlanan etiketlerin her bir kümeye atanması, eğitimden veya bütün görüntünün sınıflandırılmasından sonra yapılır. Kontrolsüz eğitim, kategoriler için herhangi bir ön bilgi gerektirmediğinden, rölatif homojen alanların, potansiyel kontrollü eğitim alanları olarak göz önüne alınması yararlı olabilir.

4.3.5. İstatistiksel Sınıflandırıcılar

Sınıflandırma algoritmaları parametrik ve parametrik olmayan algoritmalar olarak ikiye ayrılmaktadır. Parametrik sınıflandırma algoritmalarında, görüntü verisi için özel bir istatistiksel dağılım kabulü yapılır ve piksellerin atanacağı her bir sınıf için belirli kantitatif istatistiksel karakteristiklerin belirlenmesi gerekir. Bu karakteristik istatistiksel parametreler, görüntüde her bir sınıfı temsil eden eğitim veri kümesinden üretilir [72]. Oluşan özellik uzayı, eğitim veri kümesinden belirlenen karar sınırlarının oluşturduğu diskriminant hiper-yüzeylerle sınıflara ayrılarak kümelenir. Hiper yüzeyler eğer hiper-düzlemler şeklindeyse sınıflandırma problemi lineer bir karakterdedir. Genellikle sınıflandırma problemlerinde lineer olmayan diskriminant hiper-yüzeyler oluşur ve bu yüzeyler sınıfları tam bir doğrulukla ayırt edemez. Bu ise sınıflandırma hatalarının oluşmasına neden olmaktadır. Bu tez çalışmasında istatistiksel sınıflandırma yöntemi olarak Maksimum Olabilirlik-Bayes yöntemi esas alınmıştır.


4.3.5.1 Maksimum Olabilirlik Yöntemi

Maksimum Olabilirlik karar kuralı yönteminde X ölçme paterni, en yüksek olasılık değerine sahip olduğu sınıfa atanır [85], [24]. Uygulamada genellikle Gauss (normal) dağılımı kullanılmaktadır. Bu yöntem, her bir sınıf eğitim verisinin çok değişkenli normal dağılım (Gauss) gösterdiğini kabul etmektedir [86]. Pratikte tam olarak normal dağılıma uyan hiçbir olay olmamasına rağmen uzaktan algılama uygulamalarında (optik tabanlı veriler için) gözlenmiş olan olasılık bazlı işlemleri yeterli bir biçimde modellemek için çok değişkenli normal dağılımın uygun olduğu gözlenmiştir. Ayrıca normal dağılım kabulünün dışına belirli ölçüler içinde çıkmış olsa da bu kabule dayanan algoritmaların sınıflandırma performansları açısından güçlü oldukları görülmüştür. Çok değişkenli normal dağılım varsayımının sınıflandırma doğruluğu ve maliyet faktörleri arasında iyi bir denge kurduğu ortaya konulmuştur [24]. Ayrıca, karar sınırlarının belirlenmesi için matematiksel olarak kolay işlenebilir analitik bir çözüm sunması ve kontrollü sınıflandırmada eğitim veri kümesini oluşturan piksellerin genellikle normal dağılıma benzer bir dağılım göstermesi de optik uzaktan algılama verileri için bu dağılım modelinin neredeyse evrensel bir dağılım olarak kabul edilmesini sağlamıştır.


Gauss dağılımı genel kabul görmesine karşın farklı olasılık dağılımlarının da kullanımı söz konusudur. Fakat ortalama vektör ve kovaryans matrisi ile belirlenen Gauss dağılımı, matematiksel olarak daha tatmin edici sonuçlar vermektedir. Parametrik sınıflandırma algoritmalarının parametrik olmayan algoritmalara olan üstünlüklerinden birisi veri için kabul edilen dağılıma dayanarak teorik bir sınıflandırma hatasının önceden tahmin edilebilmesidir. Parametrik olmayan sınıflandırma yöntemlerinde veri hakkında hiç bir olasılık dağılım kabulü yapılmaz.

Normal dağılım kabulüyle bir kategorinin dağılımı, ortalama vektörü ve kovaryans matrisiyle belirlenebilir. Bütün kategoriler için eğitim verilerinden hesaplanan dağılım modellerine dayanarak bilinmeyen piksellerin kategorilere ait olma olasılıkları hesaplanabilir. Bunun sonucunda pikseller en büyük olasılıkla ait oldukları sınıflara atanır. Şekil 4.5’de LANDSAT TM 3. ve 4. kanallarının oluşturduğu özellik uzayında, 4 farklı yeryüzü cismi için eğitim paternlerinin oluşturduğu Gauss olasılık yoğunluk fonksiyon eğri yüzeyleri rölatif olarak

abartılarak gösterilmiş ve Şekil 4.6'de bu objelerin Gauss Olasılık Yoğunluk Fonksiyonu eş olasılık eğrileri çizilmiştir.



Şekil 4.5: Dört farklı yeryüzü cismine ait Gauss olasılık yoğunluk fonksiyonu eğri yüzeyleri.



Şekil 4.6: Dört farklı yeryüzü cisminin Gauss olasılık yoğunluk fonksiyonu eş olasılık eğrileri.

Görüldüğü gibi özellik uzayında oluşan olasılık eğrileri parabolik, elipsoidal veya dairesel olabilir. Bunun nedeni dağılımı oluşturan matematiksel modelin kuadratik karakterli olmasıdır.

Teorik olarak bu sınıflandırma yönteminde kullanılan eğitim veri kümelerinin büyüklüğü, gereken istatistiksel parametrelerin hesaplanabilmesi için en az toplam kanal sayısından bir fazla olmalıdır. Ayrıca normal dağılımın önemli ölçüde bozulduğu, başka bir deyişle veri histogramının iki veya daha fazla doruk noktasına sahip olduğu durumlarda bu yöntem uygun değildir [71]. Her birinin ayrı bir sınıfı gösterdiği çok doruk değerli veriler tek doruk değerli (tek maksimumlu) Gauss dağılım fonksiyonuyla yeterince temsil edilemez. Bu durumda her bir doruk değeri ayrı bir küme olacak şekilde alt sınıflara bölünerek ayrı ayrı değerlendirilmelidir. Verinin doruk değerleri kontrolsüz kümeleme teknikleri kullanılarak araştırılabilir [72].

Optimum bir sınıflandırma yöntemi olarak sınıflandırma sonrası oluşan ortalama hatayı minimum yapacak bir algoritma amaçlanabilir. Bu amaca yönelik olarak geliştirilecek örnek bir algoritma aşağıda verilmektedir [87]:

Belirli bir x paterninin w_i sınıfından gelme olasılığı $p(w_i / x)$ ile gösterilir. x paterni gerçekten w_i sınıfından gelmesine rağmen, sınıflandırıcı x 'in w_j sınıfından geldiğine karar vermesi durumunda L_{ij} ile gösterilen bir kayıp (hata) oluşur. Potansiyel olarak x paterni söz konusu M sınıftan birisine ait olabilirken, x paterninin w_j sınıfına atanmasıyla oluşan ortalama kayıp;

$$r_j(x) = \sum_{k=1}^M L_{kj} p(w_k / x) \quad (4.15)$$

ile gösterilir. Bu eşitlik genellikle şarta bağlı ortalama risk veya kayıp olarak bilinir. Temel olasılık teorisinde, $p(a/b) = [p(a)p(b/a)]/p(b)$ olmak üzere;

$$r_j(x) = \frac{1}{p(x)} \sum_{k=1}^M L_{kj} p(x/w_k) P(w_k) \quad (4.16)$$

yazılabilir. $p(x/w_k)$ ifadesi w_k sınıfından gelen paternlerin olasılık yoğunluk fonksiyonunu ve $P(w_k)$, w_k sınıfının tekrarlanma olasılığını ifade eder. $1/p(x)$ ifadesi bütün $r_j(x)$ 'ler için ortak ve pozitif olmasından dolayı ihmal edilirse fonksiyonların rölatif sıralamasında herhangi bir bozulma olmaz. Böylece ortalama kayıp fonksiyonu;

$$r_j(x) = \sum_{k=1}^M L_{kj} p(x/w_k) P(w_k) \quad (4.17)$$

olur. Sınıflandırma algoritması her bir x paterni için M farklı değer hesaplar ve pikseli M olası sınıf içinden en küçük kayıp fonksiyonu veren sınıfa atar. Böylece bütün görüntü için oluşan toplam ortalama sınıflandırma kaybı minimum olacaktır. Bu yöntemle Bayes sınıflandırma algoritması denir. Böylece Bayes sınıflandırıcısı, $r_i(x) < r_j(x)$ olması durumunda tanınmayan bir x paternini w_i sınıfına atar. Burada $j=1, \dots, M$ ve $j \neq i$ dir. Diğer bir gösterimle

$$\sum_{k=1}^M L_{kj} p(x/w_k) P(w_k) < \sum_{q=1}^M L_{qi} p(x/w_q) P(w_q) \quad (4.18)$$

ise, x paterni w_i sınıfına atanır. Genellikle doğru bir karar için kayıp 0 ve doğru olmayan karar içinde (0 değil) 1 dir. Bu şartlar altında kayıp fonksiyonu;

$$L_{ij} = 1 - \delta_{ij}, \quad \begin{cases} \delta_{ij} = 0 & i \neq j \\ \delta_{ij} = 1 & i = j \end{cases} \quad (4.19)$$

dir. Bu yaklaşım önceki eşitlikte yerine konursa;

$$\begin{aligned} r_j(x) &= \sum_{k=1}^M (1 - \delta_{kj}) p(x/w_k) P(w_k) \\ &= p(x) - p(x/w_j) P(w_j) \end{aligned} \quad (4.20)$$

olur. Eğer;

$$p(x) - p(x/w_i) P(w_i) < p(x) - p(x/w_j) P(w_j) \quad (4.21)$$

olursa, Bayes sınıflandırıcısı x paternini w_i sınıfına atar. Bu eşitlik sadeleştirildiğinde,

$$p(x/w_i) P(w_i) < p(x/w_j) P(w_j); \quad j = 1, 2, \dots, M; \quad j \neq i \quad (4.22)$$

olması durumunda, 0-1 kayıp fonksiyonuna dayanan Bayes karar kuralı;


$$d_j(x) = p(x/w_j)P(w_j); \quad j = 1, 2, \dots, M \quad (4.23)$$

olur. Bir x paterni bütün $j \neq i$ için $d_i(x) > d_j(x)$ durumunda w_i sınıfına atanır. Bu eşitliğe dayanan karar fonksiyonları ortalama yanlış sınıflandırma kaybını minimize ettikleri için optimumdur. Bunun gerçekleşmesi için, her bir sınıfın tekrarlanma olasılığının ve her bir sınıftaki paternlerin olasılık yoğunluk fonksiyonlarının bilinmesi gerekir. Sınıfların tekrarlanma olasılıklarının bilinmemesi önemli bir problem oluşturmaz. Genellikle sınıf apriori olasılıkların bilinmesi oldukça güçtür. Eğer bütün sınıfların tekrarlanma olasılıkları eşitse, $P(w_i) = 1/M$ olur. Doğru olmasa bile bu olasılıklar genellikle problemin çözümünden sonra anlaşılabilir. Olasılık yoğunluk fonksiyonlarının, $p(x/w_i)$, belirlenmesi ise diğer bir problemdir. Eğer patern vektörleri n boyutluysa şekli bilinmeyen $p(x/w_i)$ fonksiyonu tahmini için çok değişkenli olasılık metotlarına ihtiyaç duyan n değişkenli bir fonksiyondur. Özellikle yeterince eğitim veri kümesi paterni yoksa veya öngörülen olasılık yoğunluk fonksiyonuna iyi uymuyorsa bu metotların uygulanması zordur. Bu nedenlerden dolayı, Bayes sınıflandırma algoritması değişik yoğunluk fonksiyonları için analitik bir ifadenin kabulüne ve bu ifadeye ait parametrelerin eğitim veri paternlerinden belirlenmesine dayanır. $P(x/w_i)$ için kabul edilen en yaygın dağılım Gauss (normal) olasılık yoğunluk dağılımıdır. Bu kabul gerçeğe ne kadar yaklaşırsa, Bayes sınıflandırma algoritması da minimum ortalama kayıp hedefine o kadar yaklaşır.

İki sınıf için tek boyutlu bir verinin sınıflandırma probleminde Gauss yoğunlukları, ortalama değer (μ_1, μ_2) ve standart sapma (σ_1, σ_2) değerleriyle belirlenir. Gauss (Normal) dağılımlı Bayes sınıflandırma yönteminde Bayes karar fonksiyonu;

$$\begin{aligned} d_j(x) &= p(x/w_j)P(w_j) \\ &= \frac{1}{\sqrt{2\pi}\sigma_j} e^{-\frac{(x-\mu_j)^2}{2\sigma_j^2}} P(w_j) \quad , \quad j = 1, 2 \end{aligned} \quad (4.24)$$

ile ifade edilir. Tek boyutlu olduğu için x paterni bir skalerdir. Şekil 4.7’de iki sınıf için olan olasılık yoğunluk fonksiyonları gösterilmektedir. İki sınıf arasındaki sınır x_0 ile gösterilen tek bir noktadır. Bu noktada $d_1(x_0) = d_2(x_0)$ olur. Eğer iki sınıfta oluşma olasılığı eşitse, $p(w_1) = p(w_2) = 1/2$ olur. Böylece karar sınırı x_0 noktasındaki $p(x_0/w_1) = p(x_0/w_2)$ değeri olur.



Şekil 4.7: İki sınıfa ait olasılık yoğunluk fonksiyonları.

Şekil 3.9’da da görüldüğü gibi bu nokta olasılık yoğunluk fonksiyonlarının kesişim noktasıdır. x_0 noktasının sağındaki herhangi bir patern w_1 sınıfına atanırken, solundaki paternler w_2 sınıfına atanır. Sınıfların tekrarlanma olasılıklarının eşit olmaması durumunda, eğer w_1 sınıfının sınıflandırma öncesi tekrarlanma olasılığı daha büyükse x_0 noktası sola, tersi durumda ise sağa kayacaktır. Bu durum sınıflandırma algoritmasının sınıflandırma kaybını minimize etme eğiliminden kaynaklanmaktadır. Örnek n boyutlu bir veri için genişletilecek olursa j . patern sınıfı için Gauss yoğunluk fonksiyonu;

$$p(x / w_j) = \frac{1}{(2\pi)^{n/2} |C_j|^{1/2}} \exp \left[-\frac{1}{2} (x - \mu_j)^T C_j^{-1} (x - \mu_j) \right] \quad (4.25)$$

olur. Yoğunluklar, tümüyle Eşitlik (4.4) ve Eşitlik (4.6)’da verilen μ_j ortalama vektörü ile C_j kovaryans matrisinin hesabı ile belirlenmektedir. M sınıf sayısı olmak üzere Bayes karar fonksiyon eşitliği;

$$d_j(x) = p(x / w_j) P(w_j); \quad j = 1, 2, \dots, M \quad (4.26)$$

dir. Pratik kullanımda üstel terimlerin hesaplama zorluğundan dolayı Eşitlik (4.26)’nın monotonik artan bir fonksiyon olan doğal logaritma ile sadeleştirilmesi daha uygun olmaktadır. Böyle bir işlemle karar fonksiyonlarının sayısal değerlerinin birbirlerine göre olan rölatif sıralamasında herhangi bir bozulma ve değişme olmaz. Yani;

$$\begin{aligned} d_j(x) &= \ln[p(x/w_j)P(w_j)] \\ &= \ln p(x/w_j) + \ln P(w_j) \end{aligned} \quad (4.27)$$

olur. Eşitlik (4.25)'deki değerin yukarıdaki eşitlikte yerine konmasıyla;

$$d_j(x) = \ln P(w_j) - \frac{n}{2} \ln(2\pi) - \frac{1}{2} \ln|C_j| - \frac{1}{2} [(x - \mu_j)^T C_j^{-1} (x - \mu_j)] \quad (4.28)$$

elde edilir. Burada $\frac{n}{2} \ln(2\pi)$ ifadesi bütün sınıflar için aynı olduğu için ihmal edilirse eşitlik;

$$d_j(x) = \ln P(w_j) - \frac{1}{2} \ln|C_j| - \frac{1}{2} [(x - \mu_j)^T C_j^{-1} (x - \mu_j)], \quad j = 1, \dots, M \quad (4.29)$$

olur. Bu eşitlik 0-1 kayıp fonksiyonuna uygun olarak Gauss (normal) dağılımlı sınıflar için Bayes Karar fonksiyonunu göstermektedir. Bu eşitlikteki karar fonksiyonları ikinci dereceden daha büyük bir terim içermediğinden hiperkuadrattır. En iyi durumda, Gauss dağılımlı paternler için Bayes kuralı her bir sınıf için ikinci dereceden genel bir karar yüzeyi oluşturur. Eğer sınıf paternleri gerçekten Gauss dağılımına sahipse, daha az ortalama kayıplı bir sınıflandırma performansı başka bir yüzeyle elde edilemez. Yani bu yöntem, Gauss dağılımlı veri için en optimal sınıflandırma algoritmasıdır ve sınıfların olasılık yoğunluk fonksiyonları normal (Gauss) dağılıma uyuyorsa, Bayes karar kuralı sınıflandırılmış bütün veri kümesi üzerindeki ortalama hata olasılığını küçültmektedir [88].

Eğer bütün kovaryans matrisleri eşitse ($C_j=C$, $j=1,2,\dots,M$), bu durumda her bir sınıf için lineer karar fonksiyonları;

$$d_j(x) = \ln P(w_j) + x^T C^{-1} \mu_j - \frac{1}{2} \mu_j^T C^{-1} \mu_j \quad (4.30)$$

şeklinde olur. Kovaryans matrisi birim matrise eşit olursa ($C=I$) ve $P(w_j)=1/M$ olarak alınırsa sınıf karar fonksiyonları;

$$d_j(x) = x^T \mu_j - \frac{1}{2} \mu_j^T \mu_j \quad (4.31)$$

olur. Bu son eşitlik En Kısa Uzaklık yönteminin karar fonksiyonudur. Böylece eğer (i) veri normal dağılıma uyuyorsa, (ii) bütün kovaryans matrisleri birim matrise eşitse, (iii) bütün sınıfların sınıflandırma öncesi tekrarlama frekansı eşitse, En Kısa Uzaklık algoritması, Bayes mantığına göre en optimum sınıflandırıcı olmaktadır.

4.3.6. Sınıflandırma Doğruluğu

Sınıflandırma hataları paternlerin yanlış sınıflara atanmasından kaynaklanır. Doğruluğun bilinmesindeki amaç sınıflandırmanın ne kadar iyi olduğunu görmektir. Hataların nedenleri ile kaynaklarının anlaşılıp uygun olarak düzeltilmesiyle üretilen tematik haritaların doğrulukları artırılabilir. Özellikle uzaktan algılama verileri karar verme işlemlerinde kullanılacaksa bu verilerin doğruluklarının bilinmesi çok önemlidir. Ayrıca uygulamada kullanılan bir çok farklı tekniğin karşılaştırılarak eldeki probleme en uygun olanının seçilebilmesi için, sınıflandırma doğruluk derecelerinin bilinmesi gereklidir [89].

Sınıflandırma doğruluk derecesinin belirlenmesinde paternlerin kategorilere atanabilmesi için gereken karar fonksiyonlarının hesaplandığı eğitim veri setinin kullanılması istatistiksel olarak yanlı, taraflı bir bakış sağlamaktadır. Böyle bir yaklaşım, doğruluğu tam olarak yansıtamayacağından karar sınırlarının belirlenmesinde kullanılmamış, eğitim veri kümesinden farklı aynı sınıfları temsil eden yeni bir test kümesinin oluşturulması gerekir [72]. Bu şekilde test veri kümesi üzerinden hesaplanan doğruluklar istatistiksel olarak yansız ölçütler olacaktır.

4.3.6.1 Genel Doğruluk

Doğruluğun kantitatif belirlenmesinde referans verisiyle genel veri karşılaştırılır. Bu işlemde referans verisinin doğru olduğu kabul edilir. Kantitatif sınıflandırma doğruluk derecesinin belirlenmesinde en çok kullanılan yöntem, hata matrisi oluşturmaktır. Şekil 4.8’de bu matrisin matematiksel ifadesi gösterilmektedir.

		j = Sütunlar (Referans)			Kolon Toplamı
		1	2	k	n_{i+}
i = Satırlar (Sınıflandırma)	1	n_{11}	n_{12}	n_{1k}	n_{1+}
	2	n_{21}	n_{22}	n_{2k}	n_{2+}
	k	n_{k1}	n_{k2}	n_{kk}	n_{k+}
Sütun Toplamı		n_{+1}	n_{+2}	n_{+k}	n

Şekil 4.8: Hata matrisi.

Bu matrisin oluşturulmasında toplam n paternden oluşan eğitim verisindeki her bir paternin k sınıftan birine atandığı $k \times k$ boyutlu gride dağıtıldığı kabul edilsin. Bu gridin satırları sınıflandırılmış veriyi, sütunları referans veriyi temsil etmektedir. n_{ij} , referans veride j kategorisindeyken ($j = 1, 2, \dots, k$) sınıflandırılmış veri içinde i sınıfına ($i = 1, 2, \dots, k$) atanan paternlerin sayısını gösterir. i kategorisine atanan sınıflandırma verisindeki patern sayısı;

$$n_{i+} = \sum_{j=1}^k n_{ij} \quad (4.32)$$

ve, j kategorisine atanan referans verisindeki patern sayısı;

$$n_{+j} = \sum_{i=1}^k n_{ij} \quad (4.33)$$

ile belirlenir. Sınıflandırılmış veriyle referans verisi arasındaki genel doğruluk ifadesi;

$$GD = \frac{\sum_{i=1}^k n_{ii}}{n} \quad (4.34)$$

eşitliğiyle verilir. Geleneksel olarak sınıflandırma doğruluğu, genel doğrulukla ölçülür. Bununla beraber tek bir doğruluk ölçütü olarak, genel doğruluğun kullanılması her bir sınıf için sınıflandırma performansının nasıl olduğu hakkında bilgi vermemektedir [90]. Özellikle sınıflandırma doğruluğunun bir sınıf için yüksek olması diğer sınıflar kötüde olsa genel doğruluğu etkileyecektir. Buda genel sınıflandırma doğruluk ölçütünün objektif olmamasını yani istatistiksel anlamda yanlış bir ölçüt olduğunu göstermektedir. Böyle bir yanlış durumdan kaçınmak için her bir sınıfın doğruluk ölçütü (üretici ve kullanıcı doğrulukları) kullanılabilir. Üretici doğruluğu;

$$UD_j = \frac{n_{jj}}{n_{+j}} \quad (4.35)$$

ve kullanıcı doğruluğu,

$$KD_i = \frac{n_{ii}}{n_{i+}} \quad (4.36)$$

eşitlikleriyle gösterilir. Üretici doğruluğu, gerçekten ait olduğu sınıftan başka sınıflara atanan paternlerin o sınıfa ait eğitim veri kümesindeki oranı, diğer bir deyişle yanlış sınıflandırma oranıdır. Kullanıcı doğruluğu ise bir sınıfa atanan paternlerin gerçekten bu sınıfa ait olma doğruluğudur.

4.3.6.2 Kappa Doğruluğu

Kappa analizi, hata matrislerinin birbirlerinden ne kadar farklı olduğunu istatistiksel olarak belirlemek için kullanılan ayrık çok değişkenli bir analizdir [91]. Kappa doğruluk analizi, hata matrisindeki genel doğrulukla (diyagonal elemanlara dayanan) olasılıklı doğruluk (köşegen olmayan elemanları içeren) arasındaki farka dayanır. Kappa analizi, bir sınıflandırma işleminin, paternlerin rasgele olarak sınıflara atandığı diğer bir sınıflandırmaya göre ne kadar daha iyi olduğunu göstermektedir [92]. Kappa istatistiği, sınıf doğruluk ölçütlerinin genel sınıflandırma doğruluğuna

dahil olması için kullanılır [93]. Sınıflar arası doğrulukları da içerdği için genel doğruluk ölçütünden daha iyi bir ölçüdür [90]. Kappa doğruluk değeri,

$$KaD = \frac{\frac{\sum_{i=1}^k n_{ii}}{n} - \frac{\sum_{i=1}^k n_{i+} n_{+i}}{n^2}}{1 - \frac{\sum_{i=1}^k n_{i+} n_{+i}}{n^2}} \quad (4.37)$$

ile hesaplanmakta olup, buradaki $\frac{\sum_{i=1}^k n_{i+} n_{+i}}{n^2}$ ifadesi olasılıklı doğruluğu göstermektedir.

5. YAPAY SİNİR AĞLARI VE SINIFLANDIRMA TEKNİKLERİ

Klasik problem çözme yaklaşımlarında, bilinen ortamlara yönelik sistem tepkileri önceden bilinen koşullar için üretilebilirken, beklenmeyen koşullar için uygun çözümler bulunamamaktadır. Günümüz problemleri zamanla değişmekte olup oldukça karmaşık ve kaotiktir. Klasik algoritmaların bu tip problemleri modellemesi ve çözüm üretmesi gün geçtikçe zorlaşmaktadır. Bu yönden bakıldığında, bilim, finans, mühendislik ve askeri alanlar gibi değişik uygulama alanlarına yapay zeka yada uzman sistemlerin uygulanması önemli bir yaklaşım oluşturmaktadır. Uzman sistemler; düşünen, hisseden, öğrenen ve anımsayan insan beyninin canlı sinir hücrelerinin karşılıklı bağlantılarından oluşan doğal sinir ağları işlevlerinin herhangi bir biçimde makineler tarafından taklit edilmesini inceleyen bir bilim dalıdır.

İnsan beyninin sahip olduğu işlevselliğin biyolojik yönünden daha çok bu işlevselliğin oluşumundaki modellerle ilgilenilmektedir. Yapay Sinir Ağları (YSA) konusundaki araştırmaların amacı, bu işlevsellik içerisinde insan beyninin model hesaplarını nasıl kurduğunu ve yaptığını anlamak ve daha sonra bu hesaplama gücünü belirli ölçülerde taklit eden ya da tekrarlayan sinir ağı modellerini geliştirmektir. Yapay Sinir Ağlarına olan ilginin artması, teknolojik ilerlemeler sağlamak kadar beyin nasıl çalıştığının daha ayrıntılı bir şekilde anlaşılması isteğinden de kaynaklanmaktadır. Bu istek, alışılmış sayısal bilgisayarlar için çok zor olduğu kanısına varılan çeşitli problemleri çözecek güçlü bir bilgisayar türünün oluşturulmasına da ortam hazırlamaktadır [94].

YSA'nın tarihsel gelişimi hem kavramsal, hem de uygulama alanındaki yeniliklerle birlikte olmuştur. YSA ile ilgili ilk çalışmalar 19. yy sonları ile 20. yy başlarında, Helmholtz, Ernst Mach ve Ivan Pavlov gibi bilim adamlarının fizik, psikoloji ve nöro-psikoloji alanlarında yaptığı çalışmalardır. Bu ilk çalışmalarda öğrenme, görme, şartlanma gibi konuların genel teorileri vurgulanmış fakat nöron işlemlerin özel matematiksel modeli incelenmemiştir. YSA'ya modern bakış, 1940'larda Warren McCulloch ve Walter Pitts'in çalışmalarıyla başlamış ve prensipte yapay nöronlardan

oluşan ağların aritmetik ve mantıksal fonksiyonlarının hesaplanabileceği gösterilmiştir [95].

McCulloch ve Pitts'in çalışmalarını Donald Hebb'in çalışmaları izlemiş ve Pavlov'un keşfettiği klasik şartlanmanın bireysel nöronların özelliklerinden dolayı olduğu ileri sürülerek biyolojik nöronlarda öğrenme için yeni bir mekanizma geliştirilmiştir [96].

YSA ile ilgili ilk pratik uygulama 1950'lerin sonunda yapılmıştır. Frank Rosenblatt, "Perseptron Ağı" ve ilgili öğrenme kuralını keşfederek bu ağın patern tanıma problemini çözebilme kabiliyetini göstermiştir [97]. Bu erken başarı YSA'ya büyük bir ilgi duyulmasına ve bu konudaki araştırmaların artmasına neden olmuştur. Fakat daha sonra basit perseptron ağının sadece sınırlı sayıda problem çözebildiği gösterilmiştir. Bu sırada Bernard Widrow ve Ted Hoff yeni bir öğrenme algoritması tanımlayarak bu algoritmayı, Rosenblatt'ın perseptron ağına hem yapı hem de kapasite (performans) olarak benzeyen "Adaptif Lineer Nöral Ağı"nın eğitimi için kullanmıştır [98]. Widrow-Hoff öğrenme kuralı günümüzde hala kullanılmaktadır.

Fakat hem Rosenblatt'ın hem de Widrow'un geliştirdiği YSA yapılarının sahip oldukları benzer sınırlamaların Marvin Minsky ve Seymour Papert tarafından yayınlanması sonrasında, [99] Rosenblatt ve Widrow, bu sınırlamaları ortadan kaldırmak için yeni ağlar önermelerine rağmen öğrenme kurallarını yeni önerdikleri ağlara uygun olarak değiştirememişlerdir.

Minsky ve Papert'in bu yayını, çoğu araştırmacıya YSA çalışmaları için artık son noktaya geldiği izlenimini vermiştir. Özellikle bu dönemde hızlı dijital bilgisayarların olmaması da, YSA ile ilgili çalışmaların genel olarak bir süre askıya alınma nedenlerinden birisi olmuştur. Bununla beraber 1970'lerde YSA alanında bazı önemli çalışmalar devam etmiştir. 1972'de Teuvo Kohonen ve James Anderson birbirlerinden bağımsız olarak hafıza gibi davranabilen yeni nöral ağlar geliştirmiştir [100], [101]. YSA çalışmaları açısından durgun olan bu sürede oldukça aktif olan bilim adamlarından birisi de Stephen Grossberg olup, "Self-Organizing Neural Network" yapılarının tanıtımında başarılı çalışmalar yapmıştır [102]. 1980'lerde yeni kişisel bilgisayarların ve iş istasyonlarının kapasitelerinin herkesin kullanabileceği bir şekilde artması ve ayrıca önemli yeni kavramların ortaya çıkması, YSA ile ilgili

çalışmalarda patlamaya neden olmuştur. İki yeni kavram, YSA'nın bu ikinci kez yeniden doğuşunun en önemli etkenleri olmuştur. Birincisi, birleşik hafıza olarak kullanılabilecek tekrarlı bir ağıın çalışma prensiplerini açıklamak için istatistiksel mekaniğin kullanılmasıdır. Bu, fizikçi John Hopfield tarafından bir seminer sunumu olarak açıklanmıştır [103]. 1980'lerin ikinci anahtar gelişimi birkaç araştırmacı tarafından ayrı ayrı çok katmanlı perseptron ağların eğitilmesi için geliştirilen geri yayılım algoritmasıdır. Bu konuda en etkin ve açıklayıcı yayın, David Rumelhart ve James McClelland tarafından yapılmıştır [191].

Bütün bu yoğun YSA araştırmalarında geliştirilen yeni YSA mimari yapıları ve öğrenme algoritmalarıyla ilgili bazı yeni kavramlar ortaya çıkmıştır. Bu kavramların, klasik istatistik alanında karşılıkları olmasına rağmen oldukça benimsenerek YSA ile çalışan araştırmacılar tarafından sıklıkla kullanılmıştır. İstatistik alanında kullanılan kavramlara karşı YSA çalışmalarında kullanılan kavramlar Tablo 5.1'de verilmektedir [104].

Tablo 5.1: İstatistik ve YSA arasındaki benzer yönler.

İSTATİSTİK	YSA
Model	Ağ
Tahmin	Öğrenme
Regresyon	Kontrollü Öğrenme
Enterpolasyon	Genelleme
Gözlemler	Eğitim Kümesi
Parametreler	Sinaptik Ağırlıklar
Bağımsız Değişkenler	Girişler
Bağımlı Değişkenler	Çıktılar
Ridge Regresyonu	Ağırlık Budama

5.1. Tanım ve Özellikler

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

- Yapay Sinir Ağı, paralel yapıda çalışan çok sayıda basit işlemci elemandan oluşan, fonksiyonelliği ağı yapısıyla, bağlantılarının etkinliğiyle ve işlemci elemanlardaki bağlantı işlemleriyle belirlenen bir sistemdir [105].

- Yapay Sinir Ağı (YSA), deneysel bilgiyi depolayıp ve kullanıma uygun hale getirebilen bütünüyle paralel dağılımlı bir işlemci yapısıdır. 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 [106].

- 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 [107].

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 çözilemeyen problemlerin var olması durumlarında etkin olarak kullanılabilecek bir yaklaşımdır. YSA'nın işlemsel özellikleri [106]:

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. Örneğin konuşma (ses) sinyali tanıma gibi.

2- Öğrenme (Giriş-çıkış projeksiyonu): 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 ağırlık 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. Ağırlık 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 ağırlık genelleme özelliğidir [108].

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 eğitilebilir. 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 ağırlık hafıza birimidir. Bu ağırlıklar ağırlık o anda sahip

olduğu bilgiyi veya uygulanan örneklerden öğrenmiş olduğu davranışı içerir. Bu bilgiler, ağdaki 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 ağdaki dağıtılmış karakterinden dolayı ağın performansı ani ve büyük bir çöküntü şeklinde kayba uğramadan dereceli olarak yavaşça azalacaktır.

YSA'da bilgi, ağdaki tüm bağlantılara dağıtılmıştır. Giriş veri kümesinde bulunabilecek herhangi bir gürültülü veri, bütünüyle ağırlıklar üzerine dağıtılacağından etkisi tolere edilebilir. Geleneksel yöntemlere göre hatayı tolere etme yetenekleri daha fazladır [108].

8- YSA-VLSI entegrasyonu: YSA bütünüyle paralel olan yapısından dolayı belirli görevler için gereken hesaplama hızını potansiyel olarak sağlayabilir. Bu özellikten dolayı nöral ağ, VLSI (çok geniş ölçekli entegre edilmiş) teknolojisinin gerçekleştirilmesi için kullanılabilir. VLSI teknolojisi nöral ağlara patern tanıma, sinyal işleme ve kontrol alanlarında eş zamanlı veri işleme imkanı verebilir.

9- Nörobiyolojik benzeşim: YSA'nın tasarlanmasında beynin model alınması, hata toleranslı paralel işlem yapmanın hem fiziksel olarak mümkün olduğunu hemde hızlı ve güçlü olduğunu göstermektedir. Nörobiyologlar YSA'ya nörobiyolojik fenomenin yorumlanması için bir araştırma aracı olarak bakmaktadır. Örneğin YSA okülomotor sistemdeki (göz hareketlerini sağlayan sistem) ön motor devrelerin ve sinyali işleme şekillerinin geliştirilmesinde kullanılmaktadır.

10- 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.

5.2. Biyolojik Sinir Ağı: Beyin

Beyin, her biri yaklaşık binden yüz bine kadar sinir hücresinden oluşan, işlevsel birimleri üst düzeyde tümleştirilmiş bir sistemdir. Her bir hücre, eleman başına yaklaşık 10^4 bağlantı ile diğer hücrelere bağlanır. Bu elemanlara nöron denir. Merkezi sinir sistemimiz kabaca bir trilyon hücreden oluşmaktadır.


İnsan beyninin değişik iki işlevinin olduğu bilinmektedir. Birincisi, bilinçli olarak tanımlanmış ardışık adımlardan oluşan bir işlemin mantıksal olarak sıralanması işlevidir. Program olarak listelenmiş istekleri ardışık olarak işleyen günümüzün sayısal bilgisayarları, beynin bu işlevinden esinlenerek, 1940'lı yıllarda bulunan ardışık bilinçli düşünme teorisinin bir sonucu olarak geliştirilmiştir. İkincisi ise

öncekinden çok daha karmaşık yapıda olan bilinç dışı düşünme ya da bilinç dışı zekâdır. Duyu organlarımız tarafından algılanan çevremize ait birçok veri, algılama ve öznitelik çıkarma süreçlerinden bilinç dışı olarak geçmektedir. Örneğin; hareketlerimizin üç boyutlu uzaydaki uyarı ve tepki sinirleri aracılığıyla denetimi büyük oranda bilinç dışı bir işlemdir (düşünmedir). Bilinç dışı düşünme yapısı, belleğimizin büyük bir yeteneğe sahip olmasındaki temel etkidir. Bilinç dışı gerçekleştirilen işlevlerin tamamı, birbirine yakın karşılıklı bağlantılardaki etkileşim ve elektro-kimyasal süreçlerle sinir hücrelerinin oluşturduğu ağlarda paralel olarak çalışır.

Beynimiz kendini düzenleme, öğrenme ve ilişki kurma yeteneklerine sahiptir. Biyolojik bilgi işlem modellerinin (beyin) taklit edilmesinde farklı düzenleme ve düşünce seviyeleri oluşturulmaktadır. Ağ seviyesinde, ağı oluşturan benzer sinir hücrelerinin karşılıklı bağlantıları uyarı-tepki işlevlerini tanımlamak için incelenmektedir. Algılama ve problem çözme gibi akılsal işlev seviyesinde, ağlar çok daha karmaşıktır. Bunlar biyolojik bilgi işlem sürecinin en üst seviyedeki ağlarıdır.

Sinir hücresi (nöron), hücre çekirdeğini saran bir hücre gövdesinden oluşur. Hücre gövdesinden çıkan ve akson olarak adlandırılan uzantılar, diğer hücrelere bağlanan çok sayıda dallara ayrılır. Akson, hücre gövdesinden dışarı diğer nöronlara sinyalleri taşıyan uzun bir fiber yapısıdır. Bu uzantılar dallar üzerinden diğer hücrelerle eşleşen (sinaptik) en yakın ve işlevsel bağlar oluşturur ve bir hücreden diğerine bilgi aktarır. Eşleşen bağ, diğer hücrenin bilgi alıcı uzantısı olan dendrit ile sonlanır. Dendritler ağaca benzeyen topolojik bir yapıda elektrik sinyallerini hücre gövdesine taşıyan sinir fiber ağlarıdır.

Bir hücre, diğer hücre tarafından eşleşen bağlar ile uyarılır. Uyarı şiddetinin belirgin bir eşik değerini aşmasıyla eylem potansiyeli oluşur. Bu potansiyel yükseldikten sonra aniden düşer ve hücre sakin konumuna döner. Hücre uyarı şiddeti ya da bilgi yoğunluğu eylem potansiyellerinin sıklığı ile belirlenir. Daha büyük uyarılar, dürtülerin akson üzerindeki ardışıklığını artırır. Şekil 5.1’de biyolojik nöron hücre elemanları verilmektedir [109].



Şekil 5.1: Biyolojik sinir hücresinin (nöron) yapısı.

Nöral ağ fonksiyonunu, nöronların dağılımı (düzenlenmesi) ve karmaşık kimyasal işlemlerle gerçekleşen bireysel sinaptik bağlantıların etkinliği oluşturur. Nöral yapının bir kısmı doğuştan belirlenirken diğer kısımları öğrenmeye bağlı olarak gelişir. Öğrenme işlemi sırasında yeni bağlantılar oluşur ve zayıf olan bağlantılar pasifize edilir. Nöral yapı hayat boyu sürekli değişmektedir. Bu sonraki değişimler asıl olarak mevcut sinaptik bağlantıların güçlenmesi veya zayıflaması olarak gerçekleşir.

5.3. İşlemci Eleman (Yapay Nöron)


YSA'nın temel işlemci elemanı olan yapay nöronlar, ismini aldıkları biyolojik nöronlardan oldukça farklı olup beynin karmaşıklığına yaklaşmamaktadır. Bununla beraber biyolojik ve yapay nöral ağları arasında iki önemli anahtar benzerlik vardır. Birincisi, her iki ağın inşa edilen blokları (YSA beyinden çok daha basit olmasına rağmen) birbiriyle bağlantılı olan basit işlemsel elemanlardan oluşur. İkincisi, nöronlar arasındaki bağlantılar ağın fonksiyonunu belirler. Biyolojik nöronlar elektrik devrelerinden daha yavaş olmalarına rağmen (10^{-3} e karşı 10^{-9} sn), beyin birçok görevi konvansiyonel bilgisayarlardan çok daha hızlı yapabilmektedir. Bu özellikle biyolojik ağların bütünüyle paralel yapısından kaynaklanmaktadır. Bu yapı içinde bütün nöronlar aynı zamanda çalışmaktadır. YSA da bu paralel yapıyı taşımaktadır. Tablo 5.2'de matematiksel nöral yapının biyolojik nöral yapıyla olan benzeşimi verilmektedir.

Tablo 5.2: 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

Tek bir girişli nöron modeli Şekil 5.2’de gösterilmektedir. Bu modelde skaler giriş p , skaler ağırlık w ile çarpılmakta ve toplam fonksiyonuna tabi tutulmaktadır. Eğer modele bias (öteleme) terimi de dahil edilirse Şekil 5.3’te olduğu gibi 1 girişi bias terimiyle çarpılmakta ve w_p çarpımıyla toplanmaktadır. Toplam sonucu oluşan n değeri sıklıkla net giriş olarak isimlendirilir ve bu giriş aktivasyon (transfer fonksiyonu) fonksiyonu f ’e gönderilir. Aktivasyon fonksiyonu f , skaler nöron çıkışı a değerini üretmektedir. Gerçek nöron çıkışı, kullanılan aktivasyon fonksiyon tipine bağlıdır. Bias terimi sabit 1 giriş değeri haricinde daha çok bir ağırlık özelliği göstermekte olup bu terim istenirse ihmal edilebilmektedir. Önemli bir nokta w ağırlık ve b bias elemanlarının, işlemci elemanların dolayısıyla ağırlık güncellenebilir parametreleri olmalarıdır. Bu güncelleme, ağırlık giriş ve çıkış değerleri arasındaki belirli bir özel şartın sağlanmasıyla gerçekleştirilir. Bu özel şarta göre yapılan güncelleme işleminin matematiksel bütünlüğü öğrenme kuralı olarak adlandırılır.


Tipik olarak bir işlemci eleman birden çok girişe sahiptir. Şekil 5.4’de gösterildiği üzere R girişe sahip bir işlemci elemanda bireysel $p_1, p_2, \dots, p_R$ giriş elemanları, karşılık gelen W ağırlık matrisinin $w_{1,1}, w_{1,2}, \dots, w_{1,R}$ elemanlarıyla ağırlıklandırılır. [110]



Şekil 5.2: Bias olmaksızın tek girişli işlemci eleman modeli.



Şekil 5.3: Bias parametresiyle tek girişli işlemci eleman modeli.



Şekil 5.4: Bias elemanı ile beraber çok girişli işlemci eleman modeli.

Şekil 5.4'deki çok girişli işlemci eleman modelinde aktivasyon fonksiyonuna girecek olan ağırlıklandırılmış kümülatif işlemci eleman değeri [110];

$$\begin{aligned} n &= w_{1,1}p_1 + w_{1,2}p_2 + \dots + w_{1,R}p_R + b \\ &= Wp + b \end{aligned} \quad (5.1)$$

ve işlemci eleman çıkış değeri ise;

$$a = f(Wp + b) \quad (5.2)$$


eşitlikleri ile gösterilir.

5.4. 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 perseptron ağlarında olduğu gibi kompleks 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 yapılarında logaritmik sigmoidal veya tanjant hiperbolik ve RBF yapılarında 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, 1/C kodlama durumunda ise sigmoidal fonksiyonun değişik bir formu olan “softmax” fonksiyonu daha etkin olabilir [111]. “Softmax” fonksiyonunda amaç, çıkışların toplamını bire eşitlemektir. Böylece YSA çıkışları sınıflandırma problemlerinde aposteriori olasılıklar olarak yorumlanabilir [112], [113]. 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.

Hangi fonksiyonun kullanılacağı YSA'nın çözmeye çalışacağı problemin şartlarına bağlıdır ve etkin bir şekilde deneme yanılma yoluyla tespit edilebilir. Şekil 5.5'te gösterildiği gibi bazı aktivasyon fonksiyonları lineer iken bazıları değildir. Geri-yayılma tabanlı öğrenme algoritmaları aktivasyon fonksiyonlarının türevli olmalarını gerektirir. Tablo 5.3'te grafik gösterimleri yapılan aktivasyon fonksiyonlarının matematiksel yapısı verilmektedir [104].



Şekil 5.5: Aktivasyon fonksiyonları; (i) sigmoid, (ii) tanjant hiperbolik, (iii) lineer, (iv) keskin sınırlayıcı, (v) Gauss, (vi) çoklu-kuadratik.

Tablo 5.3: 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 değeri 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	$y_i = \frac{e^{n_i}}{\sum_{j=1}^k e^{n_j}}$

5.5. 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 [114].

5.5.1. YSA'ların Yapılarına Göre Sınıflandırılması

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

5.5.1.1 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 perseptron (Multi Layer Perseptron-MLP) [191], LVQ (Learning Vector Quantization) [115], CMAC (Cerebellar Model Articulation Control) ağları [116] ve GMDH (Group Method of Data Handling) ağları [117] verilebilir. İleri beslemeli ağlar doğal olarak giriş uzayı ile çıkış uzayı arasında statik bir projeksiyon icra ederler. Verilen bir andaki çıkış, sadece o andaki girişin bir fonksiyonudur. Ağ, statik yapılı bir hafızaya sahiptir, diğer bir ifade ile herhangi bir andaki ağ çıkış değerleri sadece o andaki giriş verilerinin bir fonksiyonudur.

5.5.1.2 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 yapılı 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 ağılar, özellikle önceden tahmin uygulamaları için uygun olmaktadır [118]. Bu ağılar çeşitli tipteki zaman serilerinin tahmininde de oldukça başarıyla kullanılmaktadır. Bu ağlara örnek olarak Hopfield ağı [103], SOM (Self Organizing Map), Elman ve Jordan ağları verilebilir [103], [115], [119], [120].

5.5.2. 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 [106]. Öğrenme algoritmalarına göre YSA'lar kontrollü öğrenme, kontrolsüz öğrenme ve kontrollü öğrenmenin özel bir formu olan takviyeli öğrenme olarak üçe ayrılmaktadır.

5.5.2.1 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 [98], Genelleştirilmiş Delta kuralı [191] ve LVQ algoritması [115] verilebilir.

5.5.2.2 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) [121] veya Kohonen tarafından geliştirilen SOM (Self Organizing Map) [115] öğrenme algoritmaları kontrolsüz öğrenmeye örnek olarak verilebilir.


5.5.2.3 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) [122], [123] takviyeli öğrenmeye örnek olarak verilebilir.

5.6. Çok Katmanlı Perseptron

Çok katmanlı perseptronlar (MLP) en çok bilinen ileri beslemeli YSA tipidir. Şekil 5.6'da tek ara katmanlı bir MLP ağ yapısı gösterilmektedir. Giriş katmanındaki işlemci elemanlar sadece giriş sinyallerini ara katmandaki işlemci elemanlara dağıtan bir tampon görevi görür. Ara katmandaki işlemci elemanlar, karşılık gelen bağlantı ağırlıklarıyla gelen bütün sinyali ağırlıklandırdıktan sonra toplayıp transfer fonksiyonundan geçirerek nöron çıkış değerini hesaplar. Çıkış katmanındaki işlemci elemanlar ara katman elemanları gibi davranarak ağ çıkış değerini hesaplar. MLP'ler bir çok öğrenme algoritması kullanılarak eğitilebilir.



Şekil 5.6: Çok katmanlı perseptron ağ yapısı.

Bu tez çalışmasında, kontrollü öğrenme algoritmaları olan Delta (D), Delta Bar Delta (DBD), Genişletilmiş Delta Bar Delta (Extended DBD), Esnek geri yayılma, Eşleştirmeli Gradyent tekniklerinden Powell-Beale, Fletcher-Rieves ve Polak-Ribiek, Kuasi Newton tekniklerinden BFGS, Tek Adım Sekant öğrenme algoritmaları ve Ölçeklendirilmiş Eşleştirmeli Gradyent algoritmaları çalışma

bölgesine ait çok spektrumlu dijital uydu görüntüsünün sınıflandırılmasında kullanılmıştır. Elde edilen sınıflandırma performansları hem Maksimum Olabilirlik yöntemiyle hem de birbirleriyle karşılaştırılmıştır.

5.6.1. Delta Geri Yayılma Öğrenme Algoritması

Delta 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 [124]. Patern sınıflandırma problemlerinde ara katman sayısının maksimum üç olabileceğini gösteren çalışmalar da bulunmaktadır [125]. Geri yayılım, çok katmanlı perseptron ağlarının 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. Geri yayılım (delta) algoritmasının [191] ve [190] formülasyonundaki notasyon aşağıda verilmektedir [188]:

- 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 (ağın ürettiği) çıkış vektörü,
- o_j ; saklı katman çıkış vektörü,
- w_{kj} ; çıkış ve ara katmanlar arasındaki ağırlıklar,
- w_{ji} ; ara ve giriş katmanları arasındaki ağırlıklar,

f ; her bir işlemci elemanın aktivasyon fonksiyonu,

P ; eğitim vektörlerinin toplam sayısı.

Tek bir eğitim verisi giriş vektörü için olan hata değeri;

$$E = \frac{1}{2} \cdot \sum_k (d_k - o_k)^2 \quad (5.3)$$

Çıkış katmanı işlemci elemanı k tarafından üretilen o_k ağ çıkış değeri işlemci eleman k 'ya gelen ağırlıklandırılmış net toplamın aktivasyon fonksiyon değeridir.

$$o_k = f(net_k) = f\left(\sum_j (w_{kj} \cdot o_j)\right) \quad (5.4)$$

Burada net_k ara ve çıkış katmanları arasındaki ağırlıklarla ara katman çıkış değerlerinin iç çarpımlarının toplamıdır. Hatayı minimize etmek için w_{kj} ağırlık değerindeki bir iterasyondan diğerine olan değişim E hata değerinin ağırlıklara göre olan türevleriyle orantılı olmalıdır. Yeni ağırlık değerleri;

$$w_{kj}(m+1) = w_{kj}(m) - \alpha \cdot \sum \frac{\partial E(m)}{\partial w_{kj}(m)} \quad (5.5)$$

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

$$\frac{\partial E}{\partial w_{kj}} = \frac{\partial E}{\partial o_k} \cdot \frac{\partial o_k}{\partial net_k} \cdot \frac{\partial net_k}{\partial w_{kj}} \quad (5.6)$$

elde edilir. Eşitlik (5.6)'daki son çarpan,

$$\frac{\partial net_k}{\partial w_{kj}} = \frac{\partial \left(\sum_j w_{kj} \cdot o_j \right)}{\partial w_{kj}} = o_j \quad (5.7)$$

ara katman işlemci eleman çıkışıdır:

$$\delta_k = -\frac{\partial E}{\partial o_k} \cdot \frac{\partial o_k}{\partial net_k} = -\frac{\partial E}{\partial net_k} \quad (5.8)$$

E değeri için Eşitlik (5.3) kullanılarak;

$$\frac{\partial E}{\partial o_k} = \frac{\partial \left(\frac{1}{2} \sum_k (d_k - o_k)^2 \right)}{\partial o_k} = -(d_k - o_k) \quad (5.9)$$

elde edilir. Eşitlik (5.8)'deki ikinci çarpan çıkış işlemci elemanı k'da kullanılan aktivasyon fonksiyonunun türevidir:

$$\frac{\partial o_k}{\partial net_k} = f'(net_k) \quad (5.10)$$

Bunun için;

$$\delta_k = (d_k - o_k) \cdot f'(net_k) \quad (5.11)$$

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

$$\begin{aligned} \Delta w_{kj} &= \alpha \cdot \delta_k \cdot o_j \\ &= \alpha \cdot (d_k - o_k) \cdot f'(net_k) \cdot o_j \end{aligned} \quad (5.12)$$

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:

$$\begin{aligned} \Delta w_{ji} &= -\alpha \cdot \frac{\partial E}{\partial w_{ji}} \\ &= -\alpha \cdot \frac{\partial E}{\partial o_j} \cdot \frac{\partial o_j}{\partial net_j} \cdot \frac{\partial net_j}{\partial w_{ji}} \\ &= -\alpha \cdot \frac{\partial E}{\partial o_j} \cdot \frac{\partial o_j}{\partial net_j} \cdot o_i \end{aligned} \quad (5.13)$$

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

$$\begin{aligned}\Delta w_{ji} &= \alpha \left(-\frac{\partial E}{\partial o_j} \cdot f'(net_j) \right) t_i \\ &= \alpha \cdot \delta_j \cdot t_i\end{aligned}\quad (5.14)$$

$\frac{\partial E}{\partial o_k}$ 'dan farklı olarak $\frac{\partial E}{\partial o_j}$ 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;

$$\begin{aligned}-\frac{\partial E}{\partial o_j} &= -\sum_k \left(\frac{\partial E}{\partial net_k} \cdot \frac{\partial net_k}{\partial o_j} \right) \\ &= \sum_k \left(-\frac{\partial E}{\partial net_k} \cdot \frac{\partial \left(\sum_j (w_{kj} \cdot o_j) \right)}{\partial o_j} \right) \\ &= \sum_k \left(-\frac{\partial E}{\partial net_k} \cdot w_{kj} \right)\end{aligned}\quad (5.15)$$

elde edilir. Eşitlik (5.8) ve (5.11)'den;

$$-\frac{\partial E}{\partial net_k} = \delta_k = (d_k - o_k) \cdot f'(net_k) \quad (5.16)$$

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

$$\delta_j = f'(net_j) \cdot \sum_k (\delta_k \cdot w_{kj}) \quad (5.17)$$

Girişten ara katmana doğru ağırlıklar için olan değişim terimi;

$$\Delta w_{ji} = \alpha \cdot f'(net_j) \cdot \sum_k (\delta_k \cdot w_{kj}) \cdot t \quad (5.18)$$

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


$$\begin{aligned}
w_{kj}(m+1) &= w_{kj}(m) + \alpha \cdot \sum^P (\delta_k \cdot o_j) \\
&= w_{kj}(m) + \alpha \cdot \sum^P ((d_k - o_k) \cdot f'(net_k) \cdot o_j)
\end{aligned}$$

ve

(5.19)

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

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 ağırlık 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 5.7'de verilmiştir [109].



Şekil 5.7: Geri-yayılım akış şeması.

Ağırlıkların güncellendiği Eşitlik (5.19)'daki türevi ölçekleyen öğrenme oranı ağ eğitime başlamadan önce belirlenmelidir. Öğrenme oranının ağına yakınsama süresine önemli bir etkisi vardır. Eğer çok küçük seçilirse kabul edilebilir bir çözüm için çok fazla sayıda adıma ihtiyaç olacaktır. Ters durumda ise hatanın hedeflenen giriş değerine ulaşmasını engelleyecek bir şekilde ağına salınım yapmasına neden olacaktır. Bu sakıncaları ortadan kaldırmak için momentum parametresi kullanımı veya öğrenme sırasında adaptif parametre seçimi gibi bir çok araştırma yapılmıştır [126].

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

[127]. Eğer ağ hata uzayında bir lokal minimum noktasına rastlarsa o noktaya takılıp global minimum noktasına ulaşmayabilir. Ayrıca sistem iki nokta arasında sıkışarak salımın 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;

$$w_{kj}(m+1) = w_{kj}(m) + \sigma \cdot \sum^P (\delta_k \cdot o_j) + \mu \cdot \Delta w_{kj}(m) \quad (5.20)$$

ve

$$w_{ji}(m+1) = w_{ji}(m) + \sigma \cdot \sum^P (\delta_j \cdot t_i) + \mu \cdot \Delta w_{ji}(m) \quad (5.21)$$

olarak elde edilir. Eklenen bu itme etkisi (μ), ağın 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 [172]. Momentum parametresi alçak-geçişli bir filtre etkisi göstererek hata yüzeyindeki küçük salınımları ve özellikleri baskılar. Momentum parametresi ağın kararlılığını bozmaksızın daha büyük öğrenme katsayısı kullanmayı sağlar. Ayrıca istikrarlı ve kararlı bir öğrenme durumunda yakınsamayı ivmelendirici bir etki yapar [110].

5.6.2. Delta-Bar-Delta Öğrenme Algoritması

Delta-Bar-Delta (DBD) öğrenme algoritması çok katmanlı perseptronlar (MLP)'da ağın yakınsama hızını arttırmak için Minai ve Williams tarafından geliştirilmiş sezgisel bir yaklaşımdır [128]. Ampirik deneyler ağırlık uzayının her bir boyutunun genel hata yüzeyi bakımından oldukça farklı olabileceğini ileri sürmektedir. Yapılan bir çalışmada hata yüzeyini oluşturan ağdaki her bir bağlantının kendi öğrenme oranı değerine sahip olmasını sağlayan sezgisel bir mekanizma önerilmiştir [129]. Temel esas, tek bir ağırlık boyutu için uygun olan adım büyüklüğünün, ağdaki diğer bütün ağırlık boyutları için uygun olmayabileceğidir. Ayrıca, bu öğrenme oranları zamanla değişmelidir. Tipik olarak standart ileri beslemeli ağlar, aynı katmandaki veya ağın

genelindeki bütün bağlantılar için tek bir öğrenme oranı kullanır. Fakat, her bir bağlantı için farklı öğrenme oranının kullanılması ve bu öğrenme oranı değerlerinin zamanla değişebilmeleri ağırlık yakınsama hızını arttırmak (zamanı azaltmak) için daha fazla serbestlik derecesi tanımlamaktadır. İleri beslemeli ağırlık mimarileri genellikle çok karmaşıktır ve ağırdaki her bir bağlantı için olan öğrenme katsayılarının optimal değerlerinin belirlenmesi çok zor ve zaman alıcıdır. Her bir bağlantı için öğrenme oranlarının nasıl otomatik olarak güncelleneceği üzerine bir çok çalışma yapılmıştır. Yapılan bir çalışmada, bağlantı ağırlık değerinin birbirini izleyen değişimlerinin farklı işarete sahip olması durumunda ağırlık değerinin salınım yapmakta olduğu ileri sürülmüştür [130]. Böylece bu bağlantı için olan öğrenme oranı azaltılmalıdır. Aynı temel esas kullanılarak, öğrenme oranını hem azaltmak hem de arttırmak için farklı bir yöntem Saridis tarafından önerilmiştir [131]. Ağırlık değişim işareti birbirini izleyen birkaç adımda salınım yaptığında öğrenme oranı azaltılmalıdır. Her bir bağlantı için farklı öğrenme oranı kullanımı gradiyent azaltımındaki yaklaşımı değiştirir. Bağlantı ağırlıkları hatanın ağırlıklara göre olan kısmi türevlerine ve ağırlık değeri noktasının çevresindeki hata yüzeyinin eğrilik ölçüsüne göre güncellenir. DBD formülasyonundaki notasyon aşağıda verilmektedir:

$E(m)$;	m anındaki hata değeri,
$w(m)$;	m anındaki bağlantı ağırlığı,
$\Delta w(m)$;	m anındaki ağırlık değişimi,
$\alpha(m)$;	m anındaki bağlantı öğrenme oranı,
$\Delta \alpha(m)$;	m anındaki öğrenme oranı değişimi,
$\delta(m)$;	m anındaki ağırlık değişiminin gradiyent bileşeni,
$\bar{\delta}(m)$;	önceki gradiyent bileşeninin m anındaki ağırlıklı ve üstel ortalaması,
θ ;	konveks ağırlıklandırma faktörü,
κ ;	sabit öğrenme oranı artımı,
ϕ ;	sabit öğrenme oranı azaltımı.

Geri yayılım algoritmasındaki gradiyent;

$$\delta(m) = \frac{\partial E(m)}{\partial w(m)} \quad (5.22)$$

dir. Geri yayılım algoritmasındaki ağırlık güncelleme eşitliği;

$$w(m+1) = w(m) + \alpha \cdot \delta(m) \quad (5.23)$$

olup burada α sabit bir öğrenme oranıdır. DBD öğrenme kuralında, her bağlantı için değişken bir öğrenme oranı $\alpha(m)$ göz önüne alınırsa ağırlık güncelleme eşitliği;

$$w(m+1) = w(m) + \alpha(m) \delta(m) \quad (5.24)$$

şeklinde elde edilir. Jacobs [129], çalışmalarında her bir bağlantı için öğrenme oranının azalması ve artması için sezgiselliğin kullanılmasında, $\delta(m)$ eğim bileşeninin ağırlıklı ortalamalarını ($\bar{\delta}(m)$) kullanmıştır. Ağırlıklı ortalama şu şekilde verilebilir:

$$\bar{\delta}(m) = (1 - \theta) \delta(m) + \theta \bar{\delta}(m-1) \quad (5.25)$$

Sezgisel olarak, önceki gradiyent bileşeni üstel olarak artarsa ve mevcut gradiyent bileşeniyle aynı işaretli ise öğrenme oranı, κ sabiti ile artırılan ağırlıkla birleştirilir. Mevcut eğim bileşeni üstel ortalamadan farklı işaretli ise, öğrenme oranı mevcut değeri ile orantılı olarak azalır. Bu öğrenme oranının güncelleştirilmesi aşağıdaki eşitlikle tanımlanmıştır:

$$\Delta \alpha(m) = \begin{cases} \kappa & \bar{\delta}(m-1) \cdot \delta(m) > 0 \\ -\phi \cdot \alpha(m) & \bar{\delta}(m-1) \cdot \delta(m) < 0 \\ 0 & \text{diğer} \end{cases} \quad (5.26)$$

Dikkat edilmesi gereken nokta, DBD algoritmasının, öğrenme oranlarını lineer olarak artırmakta fakat geometrik olarak azaltmakta olduğudur [118].

5.6.3. Geniřletilmiş Delta-Bar-Delta Öğrenme Algoritması

DBD algoritmasının sahip olduėu eksikleri ortadan kaldırmak için Geniřletilmiş Delta-Bar-Delta (Extended DBD) öğrenme algoritması geliştirilmiştir. Standart DBD algoritmasındaki bu eksiklikler;

- Momentum kullanılmaması,
- Küçük bile olsa lineer artım oranının (κ), öğrenme oranını yeterince arttırmak için ağırlık uzayında büyük atlamalara neden olabilmesi,
- Geometrik azalmanın bazen bu büyük atlamaları engellemede yeterince hızlı olamaması.

Zamanla deėişen öğrenme oranı gibi momentum parametresi de zamanla deėişen bir karaktere sahiptir. Belirli bir anda ağırlık uzayında genel hatayı belirleyerek bunu düzeltme özelliğine sahiptir. EDBD algoritmasında belirli bir andaki ağırlık hatası, bir önceki hatadan büyük ise ağırlık değerleri bir önceki ağırlık değerlerine geri döndürölür [118].

Formüllerdeki notasyon;

$\mu(m)$; m anındaki bağlantı momentum oranı,

$\Delta\mu(m)$; m anındaki bağlantı momentum deėişim oranı,

κ_α ; sabit öğrenme oranı ölçek faktörü,

κ_μ ; sabit momentum oranı ölçek faktörü,

γ_α ; sabit öğrenme oranı üstel faktörü,

γ_μ ; sabit momentum oranı üstel fonksiyonu,

φ_α ; sabit öğrenme oranı azaltım faktörü,

φ_μ ; sabit momentum oranı azaltım faktörü,

- α_{mak} ; öğrenme oranındaki üst sınır,
- μ_{mak} ; momentum oranındaki üst sınır,
- λ ; düzeltme (recovery) tolerans faktörü.

EDBD’de, her bir bağlantıdaki momentum $\mu(k)$ ve öğrenme oranı $\alpha(k)$ parametreleri zamanla değiştirilmektedir. Standart delta kuralı ile verilen momentumlu ağırlık güncelleme formülü;

$$w(m+1) = w(m) + \alpha \cdot \delta(m) + \mu \cdot \Delta w(m) \quad (5.27)$$

dir. EDBD için değişken öğrenme ve momentum oranlarıyla güncelleme formülü;

$$w(m+1) = w(m) + \alpha(m) \cdot \delta(m) + \mu(m) \cdot \Delta w(m) \quad (5.28)$$

olur. Öğrenme oranı $\alpha(m)$ ve momentum $\mu(m)$ parametreleri aşağıdaki kurallara göre dengelenir. Burada $\bar{\delta}(m)$, DBD algoritmasında olduğu gibi hesaplanır:

$$\bar{\delta}(m) = (1 - \theta) \cdot (\delta(m) + \theta \cdot \delta(m-1)) \quad (5.29)$$

EDBD’de öğrenme ve momentum oranlarının değişimi benzer şekilde olup, öğrenme oranı değişimi;

$$\Delta \alpha(m) = \begin{cases} \kappa_{\alpha} \cdot \exp(-\gamma_{\alpha} |\bar{\delta}(m)|) & \text{eğer } \bar{\delta}(m-1) \cdot \delta(m) > 0 \\ -\varphi_{\alpha} \cdot \alpha(m) & \text{eğer } \bar{\delta}(m-1) \cdot \delta(m) < 0 \\ 0 & \text{diğer durumda} \end{cases} \quad (5.30)$$

ve momentum oranı değişimi;

$$\Delta\mu(m) = \begin{cases} \kappa_{\mu} \cdot \exp(-\gamma_{\mu} |\bar{\delta}(m)|) & \text{eğer } \bar{\delta}(m-1) \cdot \delta(m) > 0 \\ -\varphi_{\mu} \cdot \mu(m) & \text{eğer } \bar{\delta}(m-1) \cdot \delta(m) < 0 \\ 0 & \text{diğer durumda} \end{cases} \quad (5.31)$$

olarak bulunur. Dikkat edilmesi gereken nokta, öğrenme ve momentum oranlarının, kendi azalma ve artma faktörlerini kontrol eden farklı sabitlere sahip olmalarıdır. $\bar{\delta}(m) \cdot \delta(m)$ ifadesinin işareti, sezgisel olarak artma mı yoksa azalma mı olduğunu belirlemek için kullanılır. Azalmanın ayarlanması DBD’de algoritmasında olduğu gibi belirlenir. Ancak öğrenme ve momentum oranlarının artırılması ağırlıklı gradiyent bileşenlerinin şiddetinin ($|\bar{\delta}(m)|$) üstel azalan fonksiyonu olarak değiştirilmiştir. Böylece, daha büyük artımlar büyük eğimli bölgelerden ziyade küçük eğimli bölgelerde yapılacaktır. Bu, atlama problemi için kısmi bir çözümdür.

Ağırlık uzayındaki salınımları ve aşırı atlamaları engellemek için, üst sınırlar her bir bağlantı öğrenme ve momentum oranları için belirlenir. Matematiksel olarak tüm bağlantılar için;

$$\alpha(m) \leq \alpha_{\max} \quad (5.32)$$

ve

$$\mu(m) \leq \mu_{\max} \quad (5.33)$$

yazılabilir. EDBD algoritmasına düzeltme özellikli bir hafıza yerleştirilmiştir. Her bir epoktan sonra kümülatif hata değerlendirilir. Hata $E(m)$, önceki minimum hatadan küçük ise m anındaki ağırlıklar en iyi değerler olarak hafızada saklanır. Tolerans parametresi λ , düzeltme sürecini kontrol eder. Spesifik olarak, mevcut hata önceki minimum hatayı aşarsa, yani

$$E(m) > E_{\min} \cdot \lambda \quad (5.34)$$

olursa, tüm bağlantı ağırlık değerleri stokastik olarak hafızada saklı olan en iyi ağırlık değerleriyle değiştirilir. Ayrıca, öğrenme ve momentum oranları, düzeltmeyi başlatmak için azaltılır [118].

5.6.4. Esnek Geri Yayılm Öğrenme Algoritması

Esnek geri yayılım (EG) öğrenme algoritmasının amacı, kısmi türevlerin olumsuz etkilerinin ortadan kaldırılmasıdır. Ağırlıkların güncellenmesinde sadece türevlerin işaretleri kullanılır. Ardışık iki iterasyonda ağırlığa göre performans fonksiyonunun türevinin işareti aynı olduğunda her bir ağırlık ve bias değeri için güncelleme faktörü değeri birden büyük bir arttırıcı katsayı ile çarpılır. Eğer farklı işaretler söz konusu ise güncelleme faktörü değeri birden küçük bir katsayı faktörü ile azaltılır. Türev değeri sıfır ise güncelleme değeri sabit kalır. Ağırlıklar salınım yaptığında ağırlık değişimi azalırken, ağırlıklar bir kaç iterasyon boyunca aynı yönde değişim gösterirse ağırlık değişimi artacaktır [132].

EG öğrenme kuralı, davranışını değiştirmek için hata fonksiyonu topolojisini kullanan bir algoritmadır:

$$\Delta w_{ij}(m) = \begin{cases} -\Delta_{ij}(m) & , \quad \frac{\partial E}{\partial w_{ij}}(m) > 0 \quad \text{ise} \\ +\Delta_{ij}(m) & , \quad \frac{\partial E}{\partial w_{ij}}(m) < 0 \quad \text{ise} \\ 0 & , \quad \text{deg ilse} \end{cases} \quad (5.35)$$

$\Delta_{ij}(m)$ parametresi Δ_0 sabit bir güncelleme değeri ile Eşitlik (5.35) “Manhattan” öğrenme kuralına dönüşür [133]. Bu yöntem ağırlıkların güncellenmesi için oldukça kabadır ve zor problemlerin çözümünde yetersiz kalmaktadır. Hata fonksiyonu hakkında ek bilgilerle algoritmanın daha etkin bir ağırlık güncelleme yöntemi elde edilebilir. Bu amaçla ikinci aşamada her bir ağırlık için kendi güncelleme değeri Δ_{ij} tanımlanır. Bu değerler, hata fonksiyonu E’nin lokal alanına göre öğrenme işlemi boyunca gelişir. Böylece ikinci bir öğrenme kuralı;

$$\Delta_{ij}(m) = \begin{cases} \Delta_{ij}(m-1).\eta^+ & \text{eger } \frac{\partial E}{\partial w_{ij}}(m-1) \cdot \frac{\partial E}{\partial w_{ij}}(m) > 0 \\ \Delta_{ij}(m-1).\eta^- & \text{eger } \frac{\partial E}{\partial w_{ij}}(m-1) \cdot \frac{\partial E}{\partial w_{ij}}(m) < 0 \\ \Delta_{ij}(m-1) & \text{eger } \text{degilse} \end{cases} \quad (5.36)$$

elde edilir. Burada $0 < \eta^- < 1 < \eta^+$ alınır. Güncelleme değeri, türevin değerinden değil birbirini izleyen iki türevin işaret değişiminden etkilenir. Karşılık gelen ağırlık w_{ij} 'nin kısmi türevi işaretini değiştirdiği zaman güncelleme değeri Δ_{ij} , η^- faktörüyle azaltılır. İşaretin değişmesi son güncellemenin oldukça büyük olduğunu ve bir lokal minimumdan atladığını gösterir. Eğer türev değeri işaretini korursa güncelleme değeri dar bölgedeki yakınsamayı ivmelendirmek için bir parça değiştirilir. Ağırlıkların güncellenmesi ilk Eşitlik (5.35) ile tek farkla aynıdır. Eğer kısmi türev işaretini değiştirirse önceki güncelleme formülü;

$$\Delta w_{ij}(m) = -\Delta w_{ij}(m-1), \quad \text{eger } \frac{\partial E}{\partial w_{ij}}(m) \cdot \frac{\partial E}{\partial w_{ij}}(m-1) < 0 \quad (5.37)$$

olarak değiştirilir. İşaret değiştiğinde adaptasyon işlemi tekrar başlatılır. Bunun anlamı bir sonraki adımda ağırlık değişimi için bir adaptasyonun olmadığıdır. Pratikte bu, önceki eşitlikte,

$$\frac{\partial E}{\partial w_{ij}}(m-1) = 0 \quad (5.38)$$

atamasıyla gerçekleştirilir. Başlangıçta bütün güncelleme değerleri (Δ_{ij}) başlangıç değerlerine (Δ_0) ayarlanır. Bu değerlerin seçilmesi öğrenme işlemi sırasında güncellendiği için kritik değildir [132].

Bu öğrenme algoritması genel olarak standart gradiyent azaltım algoritmalarından çok daha hızlıdır. Hafızada önceki değerlerin saklanması gerektirmez [134].

5.6.5. Eşleştirmeli Gradyent (Conjugate Gradient) Öğrenme Algoritmaları

Basit geri yayılım algoritması ağırlık değerlerini gradiyentin negatifi yönünde dengeler. Bu doğrultu gradiyentin hızla düştüğü doğrultu olarak bilinir. Bu

doğrultuda performans fonksiyonu da hızla düşer. Performans fonksiyonundaki hızlı düşüş, ağırlık hızlı yakınsamasını sağlamayabilir. Eşleştirmeli gradyent algoritmalarında, gradyent azaltım yöntemindeki doğrultulardan genellikle daha hızlı yakınsayan eşleştirme doğrultularında bir arama işlemi yapılır. [110].

Gradyent azaltımlı öğrenme algoritmalarında global minimuma doğru olan ağırlık güncellemesindeki adım oranını (adım büyüklüğü) belirleyen bir öğrenme oranı parametresi kullanılmaktadır. Eşleştirmeli gradyent algoritmasında adım boyutu her bir iterasyonda yeniden güncellenir. Performans fonksiyonunun o doğrultu boyunca minimize edileceği adım boyutunu belirlemek için eşleştirmeli gradyent doğrultusu boyunca bir arama gerçekleştirilir [134], [135].

5.6.5.1 Fletcher-Reeves Öğrenme Yöntemi

Bütün eşleştirmeli gradyent algoritmalarının ilk iterasyonu, negatif gradyent değeriyle belirlenen doğrultuda arama işlemiyle başlar.

$$p_0 = -g_0 \quad (5.39)$$

Mevcut arama doğrultusu boyunca gidilecek optimum mesafenin belirlenmesi için bir doğrultu araması gerçekleştirilir.

$$X_{k+1} = X_k + \alpha_k p_k \quad (5.40)$$

Daha sonra bir önceki arama doğrultusuyla eşleştirilmek üzere yeni arama doğrultusu belirlenir. Yeni arama doğrultusunun belirlenmesinde uygulanan genel yöntem bir önceki arama doğrultusu ile yeni gradyent arama doğrultusunu (gradyentin eksi işareti) lineer olarak birleştirmektir.

$$p_k = g_k + \beta_k p_{k-1} \quad (5.41)$$

Burada β_k skaler değeri, P_k ve P_{k-1} doğrultularının Hessian matrisine (performans indeksinin ikinci mertebeden türevleri) göre birbirine eşleştirmeli olacak şekilde seçilir. Yani

$$p_k \cdot A \cdot p_{k-1}^T = 0 \quad (5.42)$$

olmalıdır. Uygulamada Hessian matrisi hesaplanmaz ve eşleştirmeli gradiyent yöntemleri, β_k 'nin hesaplanmasındaki değişik yöntemlere göre çeşitlenir.

Fletcher-Reeves'in β_k için önerdiği güncelleme yaklaşımı aşağıdaki eşitlikle verilmiştir:

$$\beta_k = \frac{g_k^T g_k}{g_{k-1}^T g_{k-1}} \quad (5.43)$$

Bu ise mevcut gradiyentin norm karesinin bir önceki gradiyentin norm karesine oranıdır. Eşleştirmeli gradiyent algoritmaları genel olarak değişken değerli öğrenme oranına sahip geri-yayılma algoritmalarından daha hızlıdır. Genellikle sonucun problemde farklı olabilmesine karşın esnek öğrenmeden de hızlı oldukları söylenebilir. Eşleştirmeli öğrenme algoritmaları basit algoritmalara nazaran çok daha az hafızaya ihtiyaç duyarlar. Çok sayıda ağırlığın söz konusu olduğu YSA yapılarında kullanımları son derece uygundur.

5.6.5.2 Polak-Ribiere Öğrenme Yöntemi

Her bir iterasyondaki arama doğrultusu Fletcher-Reeves yöntemindeki ile aynıdır (Eşitlik 5.41). Buradaki β_k ifadesi;

$$\beta_k = \frac{\Delta g_{k-1}^T g_k}{g_{k-1}^T g_{k-1}} \quad (5.44)$$

olarak değiştirilerek, bir önceki iterasyondaki gradiyent değişiminin mevcut iterasyondaki yeni gradiyent değeriyle olan iç çarpımının önceki gradiyentin norm karesiyle bölümü ile elde edilir [136]. Önceki yöntemden daha fazla hesaplamaya ihtiyaç olmasına rağmen performans olarak hangisinin daha iyi olduğunu söylemek zordur. Bu yöntemin hafıza ihtiyacı Fletcher-Reeves yönteminden oldukça fazladır [110].

5.6.5.3 Powell-Beale Öğrenme Yöntemi

Tüm eşleştirmeli gradiyent algoritmalarında arama doğrultusu, periyodik olarak gradiyentinin negatifi olarak oluşturulur. Normalde algoritma iterasyon sayısı ağ parametre sayısına (ağırlık ve bias) eşit olduğu zaman standart ilk değere dönme noktası oluşur. Bununla beraber eğitimin etkinliğini arttırabilecek başka geri döndürme yöntemleri de mevcuttur. Powell-Beale yöntemi bunlardan biridir [137], [138]. Bu yöntemde eğer bir önceki gradiyent değeriyle şimdiki gradiyent değeri arasında çok az ortogonalite varsa geri başlatım işlevi gerçekleşir. Bu koşul

$$|g_{k-1}^T g_k| \geq 0.2 \|g_k\|^2 \quad (5.45)$$

eşitsizliği ile test edilir. Bu koşulun sağlanması durumunda arama doğrultusu gradiyentin negatiline geri döndürülür. Powell-Beale öğrenme algoritması bazı problemlerde Polak-Ribiere'den daha iyi sonuç verebilmektedir. Fakat algoritmanın hafıza ihtiyacı Polak-Ribiere'den biraz daha fazladır [134].

5.6.6. Ölçeklendirilmiş Eşleştirmeli Gradiyent Öğrenme Algoritması

Eşleştirmeli gradiyent algoritmaları her bir iterasyonda doğru arama işlemi gerektirmektedir. Bu işlem, her bir arama işleminde ağ giriş verilerine karşı ağı ürettiği çıkışların hesaplanmasını gerektirdiği için işlemsel olarak yoğundur. Moller tarafından geliştirilen [139] ölçeklendirilmiş eşleştirmeli gradiyent algoritması zaman alıcı bu arama işleminden kaçınacak şekilde dizayn edilmiştir. Temel esas, eşleştirmeli gradiyent algoritmasıyla, Levenberg-Marguardt algoritmasında kullanılan model güvenilir alan yönteminin birleştirilmesidir. Adım büyüklüğü;

$$\alpha_k = - \frac{p_k^T g_k}{p_k^T A_k p_k + \lambda_k \|p_k\|^2} \quad (5.46)$$

ile belirlenir. Ölçekleme parametresi λ 'nin yeterli büyük seçilmesiyle Hessian matrisinin pozitif tanımlı olması sağlanır. Bu parametrenin optimal değeri iterasyondan iterasyona değişir. Bu parametrenin değeri büyüdükçe öğrenme oranı (adım büyüklüğü) küçülür. Bu yöntem model-güvenilir bölge olarak adlandırılır Çünkü model sadece mevcut arama noktası etrafındaki küçük bir bölgede etkin

olarak güvenilirdir. Güven bölgesinin büyüklüğü λ parametresiyle kontrol edilir. Eğer $\lambda=0$ ise ağırlık vektörü arama doğrultusu boyunca minimuma doğru yaklaşır ve hata fonksiyonu kuadratik bir fonksiyonla ifade edilebilir ve payda pozitif olur. Eğer bu şartlar sağlanmazsa λ değerinin uygun olarak arttırılması gerekmektedir. İlk olarak Hessian matrisinin pozitif tanımlı olmaması durumunda payda; $-p_k^T \cdot A_k \cdot p_k$ formülü ile bölünür. Lokal kuadratik yakınsamanın doğruluğu [140];

$$\Delta_k = \frac{E(w_k) - E(w_k + \alpha_k \cdot p_k)}{E(w_k) - (E(w_j) + \alpha_k \cdot p_k^T \cdot g_k + \frac{1}{2} \cdot \alpha_k^2 \cdot p_k^T \cdot A_k \cdot p_k)} \quad (5.47)$$

ile belirlenir. Eğer bu değer 1'e yakınsarsa yakınsama iyidir ve λ değeri azaltılabilirken tersi bir durumda λ değeri arttırılabilir. λ_k değeri aşağıdaki şartlara göre güncellenebilir [140]:

$$\begin{aligned} \Delta_k > 0.75 \quad & \text{ise} \quad \lambda_{k+1} = \frac{\lambda}{2} \\ \Delta_k < 0.25 \quad & \text{ise} \quad \lambda_{k+1} = 4\lambda_k \\ \text{Degilse} \quad & \lambda_{k+1} = \lambda_k \end{aligned} \quad (5.48)$$

Eğer $\Delta_k < 0$ ise hatada bir artım olacak ve ağırlıklar güncellenmeyecektir. Bunun yerine Δ_k değerlendirilir. Sonunda algoritma yeterince geniş bir λ_k değeri için gradiyentin negatifi yönünde küçük bir adım ilerleyeceği için hata azaltımı elde edilecektir. Birbirini izleyen her bir ağırlık güncellemesinden sonra Eşitlik (5.48)'deki payda artımının pozitif olmasını sağlayan λ_k 'nın artırılma aşamaları ve lokal gradiyent yakınsamasının doğruluğuna uygun olarak λ_k 'nın güncellenmesi uygulanır.

Son derece kompleks bir algoritmadır. Bu öğrenme algoritmasında bir doğru üzerinde arama işlemi bulunmadığından hesap yükü azdır. Buna karşın iterasyon sayısı diğer eşleştirmeli gradiyent algoritmalarından daha fazladır. Hafıza ihtiyacı Fletcher-Reeves ile yaklaşık aynıdır [134], [135].

5.6.7. Kuasi-Newton Öğrenme Algoritmaları

Newton yöntemi, eşleştirmeli gradiyent yöntemine alternatif olarak hızlı optimizasyon için geliştirilmiştir. Genelde Newton yöntemi eşleştirmeli gradiyent yöntemlerinden daha hızlı yakınsamasına rağmen ileri beslemeli ağlar için Hessian matrisinin hesaplanması oldukça zor ve zaman alıcıdır. Bunun için Hessian matrisinin (ikinci mertebeden türevler) hesaplanmasına gerek olmayan yöntemler geliştirilmiş ve bunlara Kuasi-Newton adı verilmiştir. Bu yöntemlerde güncelleme işlemi aşağıdaki formülle hesaplanır:

$$X_{k+1} = X_k + \alpha \cdot p_k \quad (5.49)$$

Burada p_k , arama doğrultusu ve α , arama doğrultusu boyunca performansı yeterince azaltacak şekilde seçilen faktördür. Bu yöntemlerden bazıları aşağıda verilmiştir.

5.6.7.1 BFGS Öğrenme Yöntemi

Kuasi-Newton yöntemlerinden en başarılı olanı Broyden-Fletcher-Goldfarb-Shanno (BFGS) yöntemidir [141]. Arama doğrultusu

$$p_k = -A_k^{-1} g_k \quad (5.50)$$

olarak seçilir. A_k Hessian matrisi olup mevcut iterasyondaki ağ parametrelerinin (ağırlık ve bias) tanımladığı performans indeksinin ikinci mertebeden türevlerini belirtir. Hessian matrisinin her iterasyonda yaklaşık değerinin hesaplanması esasına dayanır. Güncelleme gradiyentin bir fonksiyonu olarak hesaplanır. Daha hızlı yakınsamasına rağmen eşleştirmeli gradiyent tekniklerinden daha fazla iterasyon işlemi ve hafıza ihtiyacı vardır. Çünkü yaklaşık da olsa hesaplanan Hessian matrisi $n^2 \times n^2$ boyutundadır. Burada n , parametre sayısı olup, bu sayı fazla ise bu yöntemin yakınsaması uzun zaman alacaktır. İlk iterasyonda A Hessian matrisi, birim matris olarak veya Jakobian matrisinin (performans fonksiyonunun ağ parametrelerine göre 1. mertebeden türevleri) tersi olarak seçilebilir. Böylece bir sonraki iterasyonda Hessian matrisi;

$$A_{k+1} = A_k + \Delta A_k \quad (5.51)$$

ile hesaplanır. ΔA elemanı değişik yollarla hesaplanabilir. BFGS yöntemine göre;

$$\Delta A_k = \frac{g_k \cdot g_k^T}{g_k^T \cdot p_k} + \frac{\Delta g_k \cdot \Delta g_k^T}{\Delta g_k^T \cdot \Delta X_k} \quad (5.52)$$

ile hesaplanır [142]. ΔX_k , k. iterasyondaki ağırlık değişimidir.

5.6.7.2 Tek Adım Sekant Öğrenme Yöntemi

BFGS yönteminin her bir iterasyonda ihtiyaç duyduğu hafıza ve işlem zamanını azaltmak için bir sekant yaklaşımına ihtiyaç vardır. Tek adım sekant yöntemi, eşleştirmeli gradiyent yöntemleriyle Kuasi-Newton yöntemleri arasındaki boşluğu dolduran bir algoritmadır. Bu yöntemdeki arama doğrultusu,


$$p_k = -g_k + \Delta X_k \cdot \left(1 + \frac{\Delta g_k^T \cdot \Delta g_k}{\Delta X_k^T \cdot \Delta g_k}\right) \cdot \frac{\Delta X_k^T \cdot g_k}{\Delta X_k^T \cdot \Delta g_k} + \Delta g_k^T \cdot \frac{g_k}{\Delta X_k^T \cdot \Delta g_k} \quad (5.53)$$

ile verilmektedir. Bu metot Hessian matrisinin tamamını kullanmaz. Her bir iterasyonda bir önceki Hessian matrisinin birim matris olduğunu kabul eder. Ayrıca matris tersi hesaplanmaksızın yeni arama doğrultusu belirlenebilir [143]. Bu algoritmanın hafıza ihtiyacı ve işlem zamanı her bir epokta BFGS algoritmasından daha az, eşleştirmeli gradiyent tekniklerinden biraz daha fazladır.

5.7. LVQ (Learning Vector Quantization)

LVQ YSA mimarisi, Kohonen tarafından önerilen bir sınıflandırma ağıdır [144], [145]. Adından da anlaşılacağı üzere, bu yöntem, n-boyutlu bir vektörü belirli sayıda temsil edici vektör kümesine ait olan 1 değerine projekte eden vektör kuantalama tekniğine dayanmaktadır [146]. Vektör kuantalama tekniği, giriş örneklerinin, önceden tanımlanan belirli sayıdaki referans vektörü etrafında kümelenmesini içerir. LVQ ağında öğrenmenin amacı bu referans vektörlerinin bulunmasıdır. Giriş değerlerinin kümelenmesi en yakın komşuluk yöntemine göre gerçekleştirilir ve referans vektörleriyle giriş vektörü arasındaki en kısa uzaklık araştırılır. Bu yöntemde Kazanan Hepsini Alır (Winner Takes All) öğrenme stratejisine sahip takviyeli öğrenme tekniği uygulanır [147].

LVQ mimarisi, giriş katmanı, öğrenmenin ve sınıflandırmanın gerçekleştirildiği ara katman (Kohonen katmanı) ve çıkış katmanından oluşur. Şekil 5.8’de bir LVQ YSA mimarisi örneği gösterilmektedir. LVQ YSA ağırları, giriş ve Kohonen katmanları arasında tamamen, Kohonen ve çıkış katmanları arasında da kısmen bağlantılıdır. Bu yapıda, her bir çıkış işlemci elemanı farklı bir Kohonen katman işlemci eleman kümesine bağlıdır. Kohonen katmanı ve çıkış katmanı işlemci elemanları arasındaki bağlantı ağırlık değerleri 1 olarak sabitlenmiştir. Giriş ve ara (Kohonen) katman arasındaki bağlantı ağırlıkları, referans vektörlerinin bileşenleridir. Ağırlık değerlerinin eğitim sürecinde güncellenmesiyle referans vektörleri yeni değerler alır. Ara ve çıkış katmanındaki işlemci elemanların çıkışları binaridir (0/1). Ağa uygulanan giriş vektörüne en yakın referans vektörüne sahip olan Kohonen katmanı, nöron kümesi için 1, diğer gruplar için ise 0 değeri üretir. 1 değerini alarak aktiflenen veya kazanan gruba bağlı olan çıkış nöronunda aktiflenir ve 1 değerini alır. Diğer çıkış katmanı nöronları ise 0 değerini alarak kapatılır [148].



Şekil 5.8: LVQ YSA mimari yapısı.

Kohonen katmanının kullanımı aşağıda verilmektedir:

- Eğitim sürecinde giriş vektörünün her bir işlemci elemana olan uzaklıkları hesaplanır ve en yakın olan işlemci eleman aktiflenir (diğer elemanlar 0 değerini alırken en yakın eleman 1 değerini alır).
- Eğer aktiflenen işlemci eleman giriş vektör sınıfına dahilse giriş vektörüne doğru hareket ettirilir.

- Eğer aktiflenen işlemci eleman giriş vektör sınıfına dahil değilse eğitim vektöründen uzaklaştırılır.
- Bu eğitim işlemi süresince işlemci elemanlar ilişkili oldukları bölgeye hareket eden sınıfa atanır.
- Sınıflandırma modunda giriş vektörünün her bir işlemci elemana olan uzaklığı hesaplanır ve tekrar en yakın uzaklığa sahip olan işlemci eleman aktiflenir. Giriş vektörü, bu aktiflenen işlemci elemanın temsil ettiği sınıfa atanır.

Öğrenme bir eğitim vektörü x ve her bir işlemci elemanın ağırlık vektörü w_i arasındaki Öklit uzaklığı d_i 'nin hesaplanmasıyla gerçekleştirilir:

$$d_i = \|w_i - x\| = \left\{ \sum_{j=1}^N (w_{ij} - x_j)^2 \right\}^{\frac{1}{2}} \quad (5.54)$$

Kazanan işlemci elemanın ağırlık vektörünün güncellenmesi:

$$w' = \begin{cases} w + \alpha(x - w) & \text{Eğer kazanan işlemci eleman doğru sınıfta ise} \\ w - \gamma(x - w) & \text{Eğer kazanan işlemci eleman doğru sınıfta değilse} \end{cases} \quad (5.55)$$

olarak yapılır. Burada α çekme parametresi ve γ , itme oranıdır. Öğrenme oranı olarak göz önüne alınabilecek bu parametreler eğitim süresince monotonik olarak azalır.

Basit LVQ ağının sahip olduğu kısıtlamaların etkilerini ortadan kaldırmak için değişik LVQ yapıları, örneğin LVQ1 ve LVQ2 vb., geliştirilmiştir.

5.7.1. LVQ1

Basit LVQ yapısında bazı işlemci elemanlar oldukça sık aktiflenirken (kazanmaya eğilimliyen) diğerleri bütünüyle pasif kalır. Bu durum özellikle işlemci elemanlar eğitim vektörlerine uzak iken gerçekleşir. Bu kısıtlamayı ortadan kaldırmak için DeSieno tarafından önerilen bir cezalandırma mekanizmasında [149] oldukça fazla kazanan işlemci eleman cezalandırılır. Gerçekte, cezalandırma mekanizması işlemci elemana eklenen bir uzaklık ötelemesidir:

$$d'_i = d_i + b_i \quad (5.56)$$

Bu uzaklık ötelemesi, işlemci elemanın kazanma frekansı ile ortalama işlemci eleman kazanma frekansı arasındaki farkla orantılıdır. Çok büyük uzaklık ötelemesi, basitçe Öklit uzaklığını baskılayabilir ve kazanan işlemci elemanın sadece gözlenen işlemci eleman kazanma frekansına bağımlı olmasına neden olur. Buna karşılık, küçük öteleme değerleri, kazanma frekanslarının eşitlenmesinde etki etmemektedir. Bu istenmeyen iki uç durum arasında uygun bir denge bulunmalıdır. Uygulamada öteleme orantılılık faktörü eğitim sırasında azaltılır.

Daha sonra LVQ1 algoritması, ötelenmemiş uzaklıkları kullanarak bir global kazanan ve ötelenmiş uzaklıkları kullanarak bir sınıf içi kazanan eleman belirler. Sınıf içi kazanan işlemci eleman aşağıda verilen formüle göre eğitim vektörüne yaklaşır:

$$w' = \begin{cases} w + \alpha(x - w) & \text{sin ifici kazanan aynı zamanda global kazanansa} \\ w - \beta(x - w) & \text{sin ifici kazanan global kazanan deg ilse} \end{cases} \quad (5.57)$$

Burada β , ikinci çekme parametresidir.

Bu arada global kazanan işlemci eleman eğer doğru sınıf değilse eğitim vektöründen

$$w' = w - \gamma(x - w) \quad (5.58)$$

formülüne göre uzaklaştırılır. Öteleme uzaklığı şu şekilde hesaplanır:

$$b_i = \mu d_{i_{\max}} (1 - N p_i) \quad (5.59)$$

Burada, $d_{i_{\max}}$ içsel olarak belirlenen maksimum uzaklık ve μ cezalandırma parametresidir. Bu parametre eğitim işlemi süresince azalır. p_i , işlemci elemanın kazanma frekansını tahmin eder ve $1/N$ ile başlatılır. N , her bir sınıf için olan Kohonen işlemci elemanlarının sayısıdır.

Güncelleme işlemi aşağıdaki şekilde yapılır:

$$p_i = \begin{cases} (1-\varphi)p_i & \text{Eger } i \text{ sınıf ıci kazanan deg ilse} \\ (1-\varphi)p_i + \varphi & \text{Eger } i \text{ sınıf ıci kazanansa} \end{cases} \quad (5.60)$$

φ sınıf içi kazanma frekanslarının güncelleştirilmesi için kullanılan bir sabittir.

5.7.2. LVQ2

Bu yapıda Kohonen tarafından geliştirilmiştir [150], [151]. LVQ2 yapısı, kazanan işlemci elemanın yanlış sınıfta olması ve ikinci en iyi işlemci elemanın doğru sınıfta olması durumları ile sınırlıdır. Bir diğer sınırlama da eğitim vektörünün bu iki işlemci elemanı birleştiren doğrunun orta noktasına yakın olması gereğidir. Kazanan yanlış işlemci eleman eğitim vektöründen uzaklaştırılırken, ikinci konumdaki işlemci eleman eğitim vektörüne doğru yaklaştırılır. Bu işlemler hatalı sınıflandırma yapılan bölgeler arasındaki sınırları düzeltir. Bu işlemlerdeki önemli seçim iki işlemci elemanın orta noktasına olan yakınlığı tanımlayan parametredir.

w_1 , kazanan fakat eğitim vektörü sınıfında olmayan bir işlemci eleman iken ikinci sıradaki işlemci eleman w_2 , eğitim vektörü sınıfındadır. Eğer x , $\frac{(w_1 + w_2)}{2}$ 'ye yakın ise kazanan işlemci eleman eğitim vektöründen uzaklaştırılır iken diğer ikinci sıradaki işlemci eleman eğitim vektörüne doğru hareket ettirilir:

$$\begin{aligned} w_1 &= w_1 - \alpha(x - w_1) \\ w_2 &= w_2 + \alpha(x - w_2) \end{aligned} \quad (5.61)$$

Bu durumdaki yakınlık x 'in w_1 ve w_2 'yi birleştiren doğruya dik olan iki düzlem arasında aşağıdaki noktalardan geçerek bulunmasını gerektirir:


$$\begin{aligned} &\frac{(w_1 + w_2)}{2} + \omega(w_2 - w_1) \\ &\frac{(w_1 + w_2)}{2} - \omega(w_2 - w_1) \end{aligned} \quad (5.62)$$

Burada ω , LVQ2'nin genişlik parametresidir.

5.8. Radyal Tabanlı Yapay Sinir Ağı Yapısı

Çok değişkenli enterpolasyon yaklaşımlarında kullanılan YSA yapılarından biridir. Ara katmandaki işlemci elemanlar girişlerin ağırlıklandırılmış şeklini kullanmamakta ve ara katmandaki işlemci elemanların çıkışları YSA girişleri ile temel fonksiyonun merkezi arasındaki uzaklığa göre belirlenmektedir. RBF YSA yapısı en genel anlamıyla radyal olarak simetrik olan ara katman işlemci elemanları içeren bir yapıdır. Şekil 5.9'de ara katman işlemci eleman yapısı gösterilmektedir. Radyal olarak simetrik olan ara katman işlemci elemanı (patern birimi) için 3 bileşen vardır:

- Giriş uzayında bir merkez vektörü: Bu vektör, giriş ve ara katmanlar arasındaki ağırlık vektörü olarak saklanır.
- Bir giriş vektörünün merkezden ne kadar uzak olduğunu belirlemek için uzaklık ölçütü: Tipik olarak bu ölçüt standart Öklit uzaklığı olarak alınır.
- Tek değişkenli olan ve uzaklık fonksiyon çıkışını giriş olarak alan işlemci elemanın çıkış değerini belirleyen bir aktivasyon (transfer) fonksiyonu.



Şekil 5.9: RBF YSA yapısının ara katman işlemci eleman (patern birimi) yapısı.


Diğer bir ifade ile ara katman işlemci eleman çıkışı, sadece merkezle giriş vektörü arasındaki uzaklığın bir fonksiyonudur.

$$f(x) = \varphi(\|x - c\|) \quad (5.63)$$

Genellikle uygulamada kullanılan RBF YSA yapısı Moody ve Darken tarafından önerilmiştir [152], [153]. Benzer algoritmalar, enterpolasyon ve yakınsama problemleri üzerine çalışan Powell [154], Broomhead ve Lowe [155] gibi araştırmacılar tarafından da önerilmiştir. Böyle bir ağ mimari yapısı Şekil 5.10'te gösterilmektedir. Burada ara katman işlemci elemanları (patern birimleri), lineer yapıdaki bir çıkış katmanına bütünüyle bağlantılıdır. İşlemci elemanlar şu şekilde tanımlanır:

$$I_k = \|X - c_k\| = \sqrt{\sum_{i=1}^N (X_i - c_{ki})^2}, \quad k = 1, 2, 3, \dots, N \quad (5.64)$$

$$v_k = e^{-\frac{I_k}{\sigma_k^2}} \quad (5.65)$$




Şekil 5.10: RBF YSA mimari yapısı.

Burada x , çok boyutlu giriş vektörü, c , giriş vektörü ile aynı boyutta merkez vektörü ve σ ise standart sapma değeridir. Ara katman işlemci elemanlarının (patern birimleri) eğitilmesi için c_k ağırlıkları ile σ_k genişliklerinin belirlenmesi gerekmektedir. Ara katman işlemci eleman fonksiyonlarının merkezi konumlarının (c_k) belirlenmesi için literatürde bazı yöntemler önerilmiştir [156], [152], [153], [157], [158].

Sınıflandırmada MLP YSA yapıları, veri uzayındaki hiper-düzlemleri oluşturan ara katman işlemci elemanlarını kullanarak sınıfları oluştururken, RBF YSA yapıları,

lokal kernel fonksiyonları kullanıyormuş gibi ayrı sınıf dağılımlarının modellenmesini sağlar (Şekil 5.11) [135].



Şekil 5.11: Üç ayrı bölgeye düşen veri noktaları. Bu sınıfları ayırmak için (a) hiper-yüzeyler, (b) her bir sınıfa bir kernel fonksiyonu yerleştirilir.

RBF YSA yapıları geri-yayılmalı MLP ağlarından daha hızlı öğrenir. Fakat artan girişle çok yüksek boyutlu RBF YSA yapılarına ihtiyaç duyulur. RBF YSA yapısı genellikle sistem modelleme, tahmin ve sınıflandırma problemlerinin çözümü için kullanılır. RBF YSA yapılarının, geri-yayılmalı MLP ağlarına göre üstünlükleri [118];

- 1- Geri-yayılmalı MLP yapılarından daha hızlı öğrenir.
- 2- Karar sınırlarının belirlenmesinde ve sınıflandırmada geri-yayılmalı MLP yapılarından daha doğru sonuçlar verebilir [159].
- 3- RBF YSA yapısının ara katmanı MLP YSA yapısı ara katmanından daha doğal bir yorumlama yeteneğine sahiptir. RBF YSA ara katman elemanları giriş uzayı için bir yoğunluk fonksiyonu temsil edebilir ve yeni bir giriş vektörünün eğitim vektörü olarak aynı dağılımın parçası olma olasılığını ortaya çıkarabilir [160].

RBF YSA yapılarının dezavantajları ise [118];

- 1- RBF YSA'nın eğitiminin ilk aşamasında merkez vektörünün belirlenmesi için kontrolsüz öğrenme yönteminin kullanılması durumunda önemli diskriminant bilgileri kaybolabilir.
- 2- Regresyon problemleri etkin bir çözüm için sınırlandırılmamış aktivasyon fonksiyonlarına ihtiyaç duyar.
- 4- Geri-yayılmalı MLP yapıları bir çok yapısal formda olabilir [110], [106], [134].

5.9. YSA ile Görüntü Sınıflandırma

YSA, verilen hedef değerlerine göre belirli bir performans kriterini sağlayarak öğrenen, dağılımdan bağımsız lineer olmayan bir fonksiyondur [161]. 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 ağın 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 el 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 [162]. 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 ağın 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.

5.9.1. 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, entropi gibi uzaysal bilgiler kullanılabilir. Bununla beraber, öncül işlemeyle elde edilen bilgilerle ağın 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.

5.9.2. Ağ Girişinin Kodlanması

Bir çok 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 [163], [164], [165], [166], [167], [168]. Şekil 5.12’de her bir spektral kanala bir giriş nöronu atanarak oluşturulan giriş kodlaması gösterilmektedir.



Şekil 5.12: YSA'da örnek giriş kodlaması.

Giriş verileri, spektral bilgiler olabileceği gibi uzaysal bilgiler de olabilir. Uzaysal bilgiler spektral bilgilerle beraberde kullanılabilir. Uzaysal bilgi doku ölçüm değeriyle (varyans vb.) temsil edilebileceği gibi doğrudan piksel değerleriyle de ifade edilebilir [169], [170].

MLP, LVQ ve RBF YSA yapılarında 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 [171], [165], [169].

Diğer bir giriş verisi kodlama yöntemi binari yöntemidir [172], [173]. Bu yöntemde 8 bitlik her bir görüntü verisi için patern başına 8 ayrı giriş kullanılmaktadır. Örnek olarak 5 kanallı görüntü verisinde her bir patern için 40 ayrı giriş söz konusudur. Yöntemin dezavantajları, artan giriş sayısına bağlı olarak artan eğitim süresi ve piksel değerlerindeki birim değişimde bile bit paternlerinde büyük değişmelerin olmasıdır. Bu durum komşu piksellerin aynı sınıfa ait olma olasılıklarının yüksek ve dolayısıyla benzer kodlara sahip olmalarından kaynaklanmaktadır [15]. Bu kodlamaya alternatif bir yöntem, binari yönteminin türevi olan gri kodlama [15] veya işlenmemiş kodlamadır [165]. Gri kodlama, bir sayıdan diğerine sadece bir bitle değişecek sayılar üreten bir yöntemdir. İşlenmemiş kodlama ise, bir enterpolasyon formu olarak düşünülebilir. Giriş verisi aralığında düzenli bir şekilde dağılmış rasgele sayıda işlemci eleman belirlenir. Daha sonra Gauss tipi bir fonksiyon her bir giriş işlemci elemanına ondalık sayıları üretmek için giriş verisini belirlenen aralığa yayar. Bu yöntemin gri kodlamaya olan üstünlüğü, sürekli kodlamanın ayrık kodlamaya tercih edilebilir olmasıdır [165].

5.9.3. Ağ Çıkışının Kodlanması

YSA çıkışlarının sınıflandırma problemleri için en doğal kodlanma şekli her bir sınıf için bir işlemci eleman kullanımıdır [163], [174], [175], [176], [177]. 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 [178], [179] atanabilir. 1/0'dan farklı olarak 0.9/0.1 gibi [180] veya 0.99/0.01 gibi [174] değerlerde atanabilir.

Literatürde analiz edilen iki farklı çıkış kodlama tekniği ise, binari ve sıcaklık kodlamasıdır [15]. Binari kodlamada, M adet sınıfı temsil etmek için sadece $\log_2 M$ tane çıkış işlemci elemanı kullanılır. Çıkış sayısının azalmasıyla eğitim süreside azalmaktadır. Fakat sınıfları temsil eden çıkış değerlerinin, iki sayının karşılıklı basamak değerlerinin farklılık ölçüsünü belirten Hamming uzaklığı daha büyük olabileceği için $\log_2 M$ 'den daha fazla çıkış işlemci elemanı kullanmakta eğitim süresini azaltabilir. Sıcaklık kodlamasında, çıkış işlemci eleman sayısı sınıf sayısına eşit olmasına rağmen n sınıfı için ilk n çıkış nöronu 1 değerini alırken geri kalanlar – 1 değerini alır. Sınıfların çıkış temsil değerleri için diğer kodlama tekniklerinden daha büyük bir Hamming uzaklığına neden olur.

Farklı bir kodlama tekniği olarak tek çıkış işlemci elemanı da kullanılmaktadır [181]. Bu yöntemde, tek olan çıkış işlemci elemanının ürettiği sürekli çıkış uzayı farklı sınıflara uygun olarak farklı bölgelere ayrılmaktadır. Tek çıkış elemanı kullanılması eğitim süresini çok fazla azaltmasına rağmen binari kodlamada belirtilen dezavantajlar daha belirgin olarak ortaya çıkmaktadır. Tek çıkışlı bir yapının performansı sınırlıdır ve ağırlık değerlerinin çok iyi ayarlanmalarını gerektirir.

5.9.4. Sınıfların Çıkarılması

Sınıflandırma problemlerinde, YSA çıkış değerleri ayrı olarak eğitilmelerine rağmen, LVQ dışında MLP ve RBF YSA yapılarının ürettiği çıkış değerleri küçükten büyüğe doğru sürekli bir aralık oluşturmaktadır. Bunun temelde iki sebebi olabilir: (i) İlki, ağırlık yoğunlukla sıfır hatayla eğitilememesi. Böylece çıkışlar eğitim verisi için bile olsa tam olarak hedef değerlerle çakışmaz. (ii) İkinci neden, sınıfları temsil

eden eğitim veri kümesinin görüntünün diğer kısımlarından belirli ölçüde farklı olması. Bu durum eğitim kategorisine uymayan değerlerin verilen sınıflar için umulandan farklı çıkış değerleri üretmesinden kaynaklanmaktadır.

Her bir sınıf için ayrı bir işlemci eleman kullanılması durumunda pikseller en yüksek çıkış değerini aldığı işlemci elemanın temsil ettiği sınıfa atanır [168], [182]. Bu uygulamada ampirik olarak belirlenen bir sınır değeriyle ağ çıkışları karşılaştırılabilir. Bütün çıkış değerleri bu sınır değerinin altında kalan pikseller, tanınmayan piksel olarak atanır [183]. LVQ yapısında doğal olarak çıkış değerleri en olasılıklı çıkış nöronu için 1 ve diğer nöronlar için 0 olarak üretilir.

Sürekli bir aralıkta üretilen YSA çıkış değerleri iki farklı şekilde analiz edilebilir:

1- 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 [184]. Diğer bir çalışmada ise, sınıflandırma doğruluğunu arttırmak için çıkış değerlerini aposteriori olasılıklara dönüştürecek bir yöntem önerilmiştir [166]. Detaylı bir çalışmada bir çok YSA sınıflandırma yapısının ürettiği çıkış değerlerinin Bayes aposteriori olasılıkları için bir tahmin değeri oldukları gösterilmiştir.

2- Sürekli aralıktaki ağ çıkış değerleri, sınıfların karışım ölçüsü olarak ele alınabilir. Su ve kara ayırımına yönelik literatürde yapılan bir çalışmada kıyı çizgisi boyunca ağ çıkış değerlerinin en yüksek ve en düşük değerler arasında yaklaşık eşit oldukları bulunmuştur [185]. Ağın lineer olmayan yapısı bu verinin en yüksek ve en düşük değerler arasında ya en düşüğe veya en yükseğe keskin sınırlanması yerine bir nokta etrafında kümelenmesini sağlamıştır. Bu yaklaşımda üretilen her bir çıkış değeri, ilgili pikselin karşılık geldiği sınıflara üyelik değerleridir. YSA'nın karışık sınıf kombinasyonlarını belirleyebilme yeteneği, eğitimde kullanılan veriler dışındaki başka veriler için de YSA'yı güçlü kılmaktadır.

5.9.5. 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 [186]. 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. Çünkü bunun için kullanılabilecek kabul edilmiş teorik bir yaklaşım yoktur. Teorik bir yaklaşım olarak, MLP yapılarının istatistiksel Maksimum Olabilirlik yöntemiyle karşılaştırabilmesi için her iki yöntemdeki serbestlik dereceleri kullanılabilir [187]. Örneğin tek ara katmanlı bir YSA MLP yapısında her bir kanal ve her bir sınıf için ayrı bir işlemci eleman kullanılırsa, parametre sayısı;

$$N_{Ag} = 3 + mn + on \quad (5.66)$$

olur. m, kanal sayısı; n, ara katman işlemci eleman sayısı ve o, sınıf sayısıdır. İlk terim (3); giriş, ara ve çıkış katmanlarının her birinin belirlenmesi için ihtiyaç duyulan parametre sayısını, ikinci kısım ise toplam ağırlıkların sayısını göstermektedir.

Maksimum Olabilirlik yöntemi için;

$$N_{MO} = 2 + om + \frac{1}{2}o(m^2 + m) \quad (5.67)$$

olur. İkinci ve üçüncü terimler kuadratik fonksiyonların hesaplanması için gereken elemanlardır [24]. Maksimum Olabilirlik yönteminde parametre sayısı kanal sayısının kuadratik derecesi iken, YSA’da bu, ara katmanın büyüklüğüne bağlıdır. YSA eşitliğinden;

$$n = \frac{N_{Ag} - 3}{m + o} \quad (5.68)$$

olur ve bu eşitlik diğerinde yerine konulduğunda;

$$n = \frac{2 + om + \frac{1}{2}o(m^2 + m) - 3}{m + o} \quad (5.69)$$

elde edilir. Örneğin p kanal verisi olarak LANDSAT TM görüntüsüne ait 6 spektral kanal ve m sınıf sayısı olarak 12 alınırsa ara katman işlemci eleman sayısı 17.94 değeri olarak bulunur. Bu değer yuvarlanarak ara katman için 18 işlemci eleman kullanılabilir.

LVQ ve RBF yapıları tek ara katmanlı ağlardır. Teorik olarak bir sınırlama olmamasına rağmen, MLP yapıları için tek veya iki ara katman yeterli olmaktadır. Uygulamalarda ara katman işlemci eleman sayısının, çıkış katmanı işlemci eleman sayısı ile (yani sınıf sayısı ile) orantılı ve giriş verisinin formatından ve sayısından bağımsız olduğu görülmüştür. [188].

Yapılan çalışmalarda sınıfların birbirlerinden ayıt edilebilmesi için özellik uzayında hiper-düzlemler gerektiği ve her bir ara katman işlemci elemanının bir hiper-düzlem tanımladığı düşünüldüğünde gereken ara katman işlemci eleman sayısının ihtiyaç duyulacak hiper-düzlem sayısına eşit olacağı gösterilmiştir [189].

5.9.6. YSA'da Eğitim

MLP ağlarının eğitilmesi için kullanılan geri yayılım ve bunun varyasyonları olan algoritmalarda ve RBF YSA yapısında eğitim, ya paternlerinin ağa bireysel girişlerinden elde edilen hataya göre ya da paternlerin ağa bütünüyle girildiklerinde elde edilen toplam hataya dayanarak gerçekleştirilmektedir. İlk yöntem sıralı veya dizisel eğitim olarak, ikinci yöntem ise grup eğitimi olarak adlandırılmaktadır. Gradyent azaltımını baz alan öğrenme algoritmalarında ağırlıkların, her bir eğitim paterninin ağa girilmesinden sonra güncellenmesi doğru bir gradyent araştırma işlemi olmamaktadır. Eğitim paternlerinin sıralı işlenmesi, programlama açısından daha kolay ve eğitim veri setinin teker teker ele alınmasından dolayı daha esnek bir yöntem olmasına karşılık daha çok zaman gerektirir ve paralel bütünlemeye daha az yatkındır [190].

LVQ yapısında ise paternler ağa tek tek sunulur. Her bir giriş vektörüyle referans vektörü arasındaki uzaklık hesaplanır ve belirli bir öğrenme kuralına göre









güncellenir. En basit LVQ öğrenme kuralında, eğer KOHONEN nöronu giriş vektörüne karşılık gelen çıkış nöronuna bağlanırsa, giriş vektörüne en yakın olan referans vektörü bu vektöre yaklaştırılır. Aksi durumda referans vektörü giriş vektöründen uzaklaştırılır. Genel olarak YSA eğitimi, aşağıdaki aşamaları içermektedir:

- 1- Eğitim ve buna karşılık gelen çıkış verilerinin belirlenmesi.
- 2- Ağ topolojisinin belirlenmesi (giriş, ara ve çıkış katmanı işlemci eleman sayıları ve MLP yapılarında ara katman sayısı).
- 3- Ağırlık başlangıç değerlerinin atanması. Bu değerler rasgele atanır. Aksi takdirde, ağırlık dağıtılmış bilgisini içeren farklı ağırlık değerlerine ulaşmak mümkün olamamaktadır [191].
- 4- Öğrenme ve momentum oranı gibi gereken ağ parametrelerinin belirlenmesi. Bu parametrelerin optimum değerlerinin deneme-yanılma yoluyla belirlenmesinin yanında adaptif yöntemlerde kullanılabilir.
- 5- Ağ eğitimini kesecek performans sınırı ve epok sayısının belirlenmesi. Sadece çok basit durumlarda ağ sıfır hatayla eğitilebilir. Ayrıca gereğinden fazla eğitim ağda genelleme kaybına neden olmaktadır. Bu nedenle ağı eğitimi gereken aşamada kesecek bir sınır değere ihtiyaç duyulur. Ağ eğitimi, önceden belirlenen hata veya epok değerine ulaştığında kesilir. Gereken hata veya epok değeri deneme-yanılma yoluyla belirlenebilir. Yada ağırlık değerleri belirli aralıklarla saklanır ve genelleme performansı test edilip en uygun ağırlık değerlerine sahip ağ seçilebilir. Bu amaçla eğitim için kullanılmayan yeni bir veri kümesi (test) kullanılır. Genelleme, ağı eğitimi sırasında karşılaşmadığı yeni veriler için kabul edilebilir çıkışlar üretebilme yeteneğidir. Başka bir deyişle YSA'nın daha önce karşılaşmadığı veriyi enterpole ve ekstrapole edebilme yeteneğidir [14]. Genellemenin derecesi YSA'nın gerçek gücü olup, genellemenin kontrol edilmesiyle, ağı eğitimi verisini ezberlemesi engellenmiş olmaktadır.

5.9.7. YSA'da Patern Tanıma ve Karar Sınırları

Maksimum Olabilirlik yönteminde amaç, sınıflandırma hatalarının (kayıplarının) minimize edilmesidir. YSA'da amaç, eğitim sürecinde ağ çıkış değerleriyle hedef değerleri arasındaki hatayı belirli bir öğrenme kuralına göre minimize ederek ağırlıkları güncellemektir. Bu işlem sınıf üyelik değerlerini belirleyen özellik uzayındaki karar sınırlarının oluşmasını sağlar. Literatürde yapılan bir çalışmada katman sayılarının fonksiyonu olarak karar sınırlarının özellikleri incelenmiş ve iki sınıflı bir patern tanıma problemi analiz edilmiştir [186]. Bu çalışmada tek çıkışlı, keskin sınırlayıcı fonksiyona sahip bir MLP yapısı kullanılarak, gradiyent azaltımsız sadece ileri beslemeli bir sınıflandırma uygulaması yapılmıştır.

Ayrıca ara katmansız bir YSA yapısının, özellik uzayında hiper-düzlem karar sınırları oluşturabilirken, tek ara katmanlı bir yapının, giriş veri uzayında sınırlanmamış konveks bölgeler oluşturabileceği gösterilmiştir. Ara katmandaki işlemci elemanlar, bir çok hiper-düzlem karar sınırları oluşturmaktadır. Çıkış katmanındaki her bir işlemci eleman, sonuç konveks karar sınırlarını üretmek için bu düzlemler üzerinde mantıksal bir “ve” operatörü gerçekleştirir. İkinci bir ara katman daha eklenerek istenen karar bölgesi üretilebilir. Bu durumda çıkış katmanı kendisine gelen bir önceki katmanın oluşturduğu konveks yüzeyler üzerinde mantıksal bir “veya” operatörü gerçekleştirir. Böylece sistematik olmayan, değişken ve rasgele biçimli karar yüzeyleri oluşturulur. İki ara katmanlı yapılar birbiriyle bağlantısız olan kapalı karar yüzeylerini de belirleyebilir. Böylece iki ara katmanlı bir yapı rastlantısal kompleks bölgeler üretebildiği için daha yüksek seviyede ara katman kullanmak gereksiz olmaktadır (Şekil 5.13).

Ağ yapısı	Karar sınırı tipi	Ayrılmış sınıflar	En genel karar yüzeyleri
Ara katman yok 	Tek hiper-düzlem		
Tek ara katman 	Açık veya kapalı konveks bölgeler		
İki ara katman 	Rastlantısal (komplekslik işlemci eleman sayısı ile sınırlıdır)		

Şekil 5.13: Patern tanımda YSA ara katmanlarının etkisi.

5.10. Uzaktan Algılama ve YSA

1980'lerin ortalarından itibaren bir çok bilimsel disiplin içinde YSA algoritmalarının uygulamaları hızlı bir şekilde gelişmiştir. Uzaktan algılamadaki kullanımı daha çok yeni olmasına rağmen uygulama alanı ve sayısı 1990'ların başlarından itibaren artmaya başlamıştır. Uygulamaların bir çoğu geri-yayılma öğrenme algoritmasıyla eğitilen çok-katmanlı perseptron (MLP) ağırları ile yapılmıştır. Bunun yanında SOM, LVQ ve RBF gibi YSA yapıları da kullanılmıştır. Analizler optik yüksek çözünürlüklü çok spektrumlu görüntülerden görüntüleme spektrometrelerine ve RADAR verilerine kadar geniş bir yelpazededir. İlk çalışmalar tek bir kaynaktan elde edilen veriler üzerinde yapılırken, YSA'nın farklı kaynaklardan elde edilen verilerin füzyonu, sınıflandırılması gibi ortak işlenmesi durumunda da oldukça başarılı ve esnek olduğu gözlenmiştir.

Literatürde görünen ilk çalışmalardan biri uzaktan algılama görüntülerinin analiziyle ilgili olarak Key ve arkadaşları [192] tarafından yayınlanmıştır. Bu çalışmada arktik bölgeye ait 5 kanallı AVHRR verisiyle 2 kanallı SMMR verisinin birleştirilmiş görüntüleri, 4 arazi ve 8 bulut sınıfı için geri-yayılma öğrenme algoritmasıyla

sınıflandırmıştır. Sonuçlar Maksimum Olabilirlik yöntemiyle kıyaslanmış ve YSA'nın avantajları ve dezavantajları irdelenmiştir.

Howald tarafından yapılan çalışmada üç katmanlı bir ağ kullanılarak LANDSAT TM görüntüsü arazi kullanımı amaçlı sınıflandırılmış ve sonuçlar Maksimum Olabilirlik yöntemiyle karşılaştırılmıştır [193]. Aynı mimari yapı Hepner ve arkadaşları [58] tarafından da kullanılmış ve sonuçlar, aynı özdeş eğitim kümelerini kullanan YSA yaklaşımının klasik sınıflandırma algoritmalarına göre daha iyi sonuç verdiğini göstermiştir. Üç katmanlı bir yapı, SAR verisi kullanılarak yapılan arazi kullanımı sınıflandırmasında Decatur [194] tarafından da kullanılmıştır. Hamming ağı, AQ (adaptive quantization) ağı, ART (adaptive resonance theory) ve BAM (bi-directional associative memory) gibi diğer YSA modelleri de göz önüne alınmış ve bütün bu modellerin uzaktan algılama uygulamalarında MLP'den daha zayıf oldukları görülmüştür. Gualtieri ve arkadaşları [195], [196], YSA'nın uzaktan algılamadaki ikinci bir önemli uygulama olanağını olan çok spektrumlu görüntülerin kümeleme çalışmalarındaki kullanımını incelemişlerdir. Araştırmacılar bu yaklaşımların, görüntüleme spektrometrelerinden elde edilen çok boyutlu görüntüleme verilerinin kümeleme çalışmalarında da uygulanma potansiyeli olduğunu göstermişlerdir [196].


Kwok ve arkadaşları [197] kontrollü öğrenmeye sahip YSA modeli LVQ ile buzul denizinin polarimetrik SAR görüntüsünü sınıflandırmış ve Maksimum Olabilirlik yöntemiyle karşılaştırmıştır. LVQ modelinin değişik bir biçimi SAR görüntülerinin sıkıştırılmasında Luttrell tarafından uygulanmış [198] ve başarılı bir şekilde 8. faktöre kadar sıkıştırma performansı rapor edilmiştir. Li ve Si [167], Kohonen SOM modelini üç katmanlı bir yapının bağlantı ağırlıklarının başlangıç değerlerini belirlemek için kullanmış ve daha sonra ağı eğitilmesi için geri-yayılma öğrenme algoritmasına uygulamışlardır. Hibrid MLP ve LVQ yapıları, Hernandez ve arkadaşları [199] tarafından görüntülerin sınıflandırılmasında kullanılmıştır. Geliştirdikleri yöntemde önce geri-yayılma algoritmasıyla MLP YSA yapısını eğitip, daha sonra MLP yapısının son ara katmanından elde ettikleri çıkışları LVQ yapısına uygulamışlar ve bu çalışmaları, hibrit yöntemlerin, homojen tek yapılardan daha iyi bir sınıflandırma performansı verdiklerini göstermiştir.

Wilkinson ve arkadaşları [200], Kuzey Atlantik Okyanusunun NOAA-AVHRR görüntülerindeki bulut paternlerinin kontrolsüz sınıflandırılmasında Kohonen-SOM YSA yapısını kullanmışlardır. Benzer bir çalışmada, Lee ve arkadaşları [201], [200] bulut sınıflandırması için doku tabanlı dört katmanlı bir yapı kullanılarak LANDSAT MSS'e ait görünür bölgeye ait tek bir kanal ile çok yüksek bulut tanıma doğruluğu elde etmişlerdir. Karşılaştırmalarda üç katmanlı bir ağ, k-en yakın komşuluk yaklaşımı ve artımlı lineer ayırım analiz yöntemleri kullanılmış ve sonuçta, dört katmanlı YSA yapısının diğer karşılaştırılan yöntemlerden daha iyi bir bulut sınıflandırma performansı verdiği ve göreceli olarak daha küçük eğitim kümesi kullanılarak da aynı sonucun elde edildiği gösterilmiştir. Benedictsson ve arkadaşlarının yaptığı bir çalışmada farklı kaynaklardan elde edilen verilerin (LANDSAT MSS görüntü verisi ile yükseklik, eğim ve görünüş gibi yardımcı topografik veriler) sınıflandırılmasında üç katmanlı bir ağ [15] ve eşleştirmeli gradiyent MLP yapısı [11] kullanılmıştır. Sonuçlar, istatistiksel yöntemlerle karşılaştırılmış ve sonuç olarak eğitim kümesinin yeterince örnekleme yapıyor olması koşuluyla YSA yapılarının istatistiksel yöntemlerden daha iyi bir performans verebildiği gösterilmiştir. YSA'da alternatif giriş verisinin temsil yollarının araştırılması da birçok araştırmacı grubu tarafından ele alınmış, örnek olarak Benedictsson ve arkadaşlarının yaptıkları uygulamalarda [15], [11] giriş vektörleri, binari veya gri kodlama teknikleriyle kodlanmıştır. Giriş verisi için benzer bir kodlama tekniği, Heerman ve Khazenie [172] tarafından yapılan bir çalışmada uygulanarak, hem simule edilmiş verinin, hem de iki farklı tarihli LANDSAT TM görüntülerinin sınıflandırılmasında üç katmanlı bir YSA yapısı kullanılmıştır.

Bishof ve arkadaşları [165] tarafından diğer bir kodlama tekniği LANDSAT TM görüntüsünün 4 sınıfa ayrılması için kullanılmıştır. Bu çalışmada bir çeşit enterpolasyon işlemi olarak göz önüne alınabilecek kaba kodlama tekniği kullanmalarına rağmen, YSA ile elde edilen genel sınıflandırma doğruluğu klasik Maksimum Olabilirlik yöntemiyle elde edilen genel sınıflandırma doğruluğundan daha iyi bulunmuştur. Bununla beraber bu çalışmada görülmüştür ki tarla sınıfı Maksimum Olabilirlik yöntemiyle daha yüksek bir doğrulukla ayırt edilebilmektedir. Bu ise, araştırmacıların dokusal özellikler ile çok spektrumlu verilerin YSA ortamında birleştirilmesi konusunda araştırma yapmasına neden olmuş ve yapılan çalışmalarda spektral veriye eklenen dokusal bilgi ile YSA daha yüksek bir genel

sınıflandırma doğruluğu üreterek daha iyi bir tarla sınıf doğruluğuna ulaşmıştır. Sınıflandırma sonrası yumuşatma uygulaması da iki katmanlı bir ağla yapılmıştır.

Kanellopoulos ve arkadaşları [202], [19] tarafından yapılan bir çalışmada, çok spektrumlu ve zamansal değişkenli SPOT görüntü verisinin 20 farklı arazi kullanımı sınıfına ayırt edilmesinde dört katmanlı bir YSA yapısı kullanılmıştır. Bağlı olarak daha büyük bir YSA mimarisi, sınıflandırma kompleksitesini arttırdığından YSA'nın iyi bir genelleme yeteneğine sahip olması için ağın eğitim süresinin oldukça uzadığı görülmüştür. Kanellopoulos ve arkadaşları [202], aynı veri setinin sınıflandırılması için hiyerarşik bir ağ yaklaşımı da kullanmışlardır. Bu yapı Şekil 5.14'de gösterilmektedir.



Şekil 5.14: Hiyerarşik YSA yapısı.

Özel sınıfların ayırt edilmesi için ikinci seviyede 2 ve üst seviyede 1 olarak 3 katmanlı ağlar dizayn edilmiştir. Uygulama sonucunda sınıflandırma doğruluğunda kayda değer bir gelişme olmamasına rağmen, kullanılan daha basit ağ mimari yapılarından dolayı gereken eğitim zamanı 4 katmanlı yapıya göre yarı yarıya azalmıştır. Bununla beraber her iki yapıda, Maksimum Olabilirlik yöntemine göre daha iyi bir sınıflandırma doğruluğu vermiştir. Hiyerarşik ağlar, uçaklardan elde edilen çok spektrumlu tarama verilerinin sınıflandırılmasında da kullanılmıştır [203].

Liu ve Xiao [204], MLP YSA yapısının eğitilmesi için bloke edilmiş geri-yayılma algoritmasını önermişler ve LANDSAT TM görüntüsünü 4 arazi kullanımı sınıfı için

sınıflandırmışlardır. Klasik MLP yapısından farklı olarak önerdikleri değiştirilmiş MLP yapısındaki saklı katman, her biri bir çıkış hücresine bağlanmış birkaç ayrı blok olarak organize edilmiştir. Sonuçlar, önerdikleri değiştirilmiş MLP yapısının standart MLP yapısına göre daha hızlı yakınsadığını ve daha doğru sınıflandırma doğruluğu elde edildiğini göstermiştir. Bununla beraber bu yeni yapı, standart MLP yapısından 4 kat daha fazla bağlantı ağırlık sayısına sahiptir.

Ryan ve arkadaşları [205], görüntüden kıyı özelliklerini elde etmek için küçük piksel bloklarını kategorize etmede YSA'yı kullanmışlardır. Kıyı çizgisini, YSA sınıflandırmasıyla elde edilen kategori haritasından piksel seviyesine indirgemek için görüntü işleme teknikleri kullanılmıştır. Dawson ve arkadaşları [206], hızlı YSA yapıları kullanarak denizlerdeki buz tabakalarının sınıflandırılmasını gerçekleştirmişlerdir. Bu yapılar, polinom tabanlı fonksiyonlara dayanmakta olup simule edilmiş veri setleriyle test edilmiştir.

Kahny ve Wiesbeck [207], 3 kanallı bütünüyle polarimetrik SAR veri setinin 8 arazi örtü kategorisine sınıflandırılması için YSA giriş parametrelerinin etkilerini incelemişlerdir. 1992'de Kahny ve arkadaşları [208] aynı SAR veri setinin sınıflandırma performansının geliştirilmesi için ön-işleme operasyonu olarak polarimetrik filtrelerin kullanımını irdelemişlerdir.

Downey ve arkadaşları [209] tarafından YSA yaklaşımları, Maksimum Olabilirlik yöntemi ve ortalamaya en yakın uzaklık sınıflandırma algoritmaları ile kapsamlı olarak karşılaştırılmıştır. Algoritmalar LANDSAT TM görüntülerinin değişik kombinasyonlarının 13 bitki örtüsü tipine ayırt edilmesinde kullanılmıştır. Araştırmalar, YSA yapılarının doğal bitki örtüsünün sınıflandırılmasında diğer klasik algoritmalarından daha iyi olduğunu ve sınıflandırma sonrası arazi gözlemlerine göre gerçek arazi örtüsünü en yüksek doğrulukla temsil ettiğini göstermiştir.

Wilkinson ve arkadaşları tarafından [210] tek ve iki ayrı tarihli SPOT çok spektrumlu görüntü verileri kullanılarak YSA ve kural tabanlı uzman sistemler arasında deneysel karşılaştırmalar yapılmıştır. Salu ve Tilton [211], çok spektrumlu görüntü verilerinin sınıflandırılması için farklı bir yapı olarak binari elmas YSA yapısını kullanmışlar ve bu yeni yapıyı en-yakın komşuluk sınıflandırma yöntemiyle ve geri yayılım algoritmasıyla eğitilen bir YSA yapısıyla karşılaştırmışlardır.

Sonuçta geliştirdikleri yeni YSA yapısının diğer iki yöntemden daha iyi bir performans sergilediğini göstermişlerdir.

Augusteijn ve arkadaşları [212], uydu görüntü verilerini sınıflandırmada farklı doku ölçülerinin (co-occurrence matrisi, Gabor filtreleri, gri-seviye farkları doku-ton analizi ve Fourier spektrumundan elde edilen özellikler vb.), performansını karşılaştırmışlardır. Çalışmaları, doku bilgisiyle birleştirilmiş LANDSAT TM'e ait 6 kanaldan oluşan veri için YSA'nın mükemmel sonuçlar verdiğini göstermiştir. Bununla beraber araştırmacılar kullanılan özellik sayısının optimum ağ performansı ve daha hızlı işlem yapabilmek için sınırlandırılması gerektiğini ortaya koymuşlardır.

Chen ve arkadaşları [213], SPOT görüntülerini sınıflandırmak için Kalman filtreleme tekniğini kullanan dinamik bir YSA yapısı tanımlamışlardır. Çalışmaları, standart geri-yayılmalı MLP ile karşılaştırıldığında önerdikleri yapının daha yüksek bir sınıflandırma oranı ve eğitim zamanında da kayda değer bir azalma sağladığını ortaya koymuştur.

Foody [214], GIS ortamında yardımcı verilerle birleştirilen uzaktan algılama görüntü veri kümesinin bulanık sınıflandırması için YSA'yı kullanmıştır. Kullanılan uzaktan algılama verisi, HH polarizasyonlu 4 X kanallı SAR görüntüsü olup, sınıflandırma hem YSA hem de diskriminant analizi ile yapılmıştır ve sonuçta YSA'nın daha iyi bir sınıflandırma performansı sergilediği görülmüştür. Sınıfların öncül olasılıkları kullanılarak sınıflandırma işlemi her iki yöntemle tekrarlanmış fakat bu defa diskriminant analizi daha yüksek bir sınıflandırma performansı ortaya koyduğundan YSA çıkışı, toprak tipine dayanan yardımcı verilerle birleştirilerek sınıflandırma genel doğruluğu %30 oranında arttırılmıştır.

Foody ve arkadaşları [215], SAR verilerinde tarımsal ürünleri sınıflandırmak için geri-yayılmalı MLP yapısını kullanmışlardır. Çalışmaları genel olarak, YSA'nın istatistiksel tekniklerden daha iyi sonuçlar verdiğini ortaya koymuş ve aynı zamanda sınıf öncül olasılık değerlerinin kullanıldığı diskriminant analiz tekniği ile üretilen sonuçların öncül olasılıksız YSA'nın ürettiği sonuçlarla kıyaslanabilir olduğunu göstermiştir [216]. Öncül bilgilerin YSA'da kullanılması için YSA çıkışları basitçe öncül olasılıklarla ağırlıklandırılmış ve yeni sınıf atamaları, değiştirilmiş aktivasyon

düzeyleri olmuştur. Öncül olasılıkların YSA modeliyle birlikte kullanılması ile sınıflandırma genel doğruluğunda %27 lik bir artma gözlenmiştir.


Kanellopoulos ve arkadaşları [217], ERS-1 SAR uydu verisi ile LANDSAT TM verisini birleştirmişlerdir. Radar verisinden olabildiğince faydalanabilmek için dokusal özellikler hesaplanmış ve TM verisiyle birlikte doku özelliklerinin farklı kombinasyonları kullanılarak, elde edilen veri, geri-yayılmalı MLP ağları ile sınıflandırılmıştır. Çalışmaları dokusal bilginin kullanımının sınıflandırma genel doğruluğunu önemli ölçüde arttırmadığını göstermiştir. Fakat dokusal bilginin kullanımıyla birlikte bireysel kategori sınıflandırma doğruluklarında %30'a varan önemli farklılıkların gözleendiği de belirtilmiştir. Birleştirilmiş TM ve SAR verileri farklı orman tiplerinin sınıflandırılması için Wilkinson ve arkadaşları [218] tarafından da kullanılmıştır. Çok algılayıcı veri kümesinin MLP yapıları ile sınıflandırma işlemi tek bir orman kategorisini içeren 9 arazi örtüsü için yapılmış ve daha sonra 8 ayrı orman kategorisi tek bir orman arazi örtü sınıfından çıkarılmıştır. Bu çalışmada da SAR verisinin TM ile birlikte kullanılması genel sınıflandırma doğruluğunu önemli ölçüde etkilememiş olmasına rağmen, SAR kanalının eklenmesi karışık iğne/geniş yapraklı sınıfların ayırt edilmesinde %13'lük bir gelişme sağlamıştır.

Hara ve arkadaşları [219], bütünüyle polarimetrik SAR görüntü verisinin otomatik sınıflandırılması için önce kontrolsüz bir YSA yapısı olan sonar LVQ yapısını kullanmışlar ve sonra performansı geliştirmek için SAR verisinin Maksimum Olabilirlik yöntemiyle tekrar sınıflandırıldığı iteratif bir algoritma kullanmışlardır.

Paola ve Schowengerdt [220], [187], LANDSAT TM görüntüsünün şehir bölge arazi kullanımı sınıflandırması için Maksimum Olabilirlik yöntemi ile geri-yayılmalı MLP yapısının karşılaştırıldığı oldukça detaylı bir çalışma yapmışlardır. Sınıflandırma genel doğruluk değerleri diğer bir çok çalışmadakine benzer olmasına rağmen Maksimum Olabilirlik ve MLP sınıflandırma yöntemleri arasındaki farklılıkları daha iyi ortaya koymak için sınıf karar sınırlarının gösterildiği iki boyutlu özellik uzayları üzerinde analizler yapılmıştır. Aynı görselleştirme teknikleri bağımsız olarak Fierens ve arkadaşları [221] ve Wilkinson ve arkadaşları [222] tarafından da geliştirilmiştir. Fierens ve arkadaşları [221], sınıflandırma işleminin gerçekleşme olgusuna açıklayıcı bir bakış açısı yakalayabilmek için özellik uzayındaki sınıf karar sınırlarının

görselleştirilmesini incelemişler, Wilkinson ve arkadaşları [222] ise, Maksimum Olabilirlik yöntemiyle YSA yöntemini özellik uzayının görselleştirilmesiyle karşılaştırmışlardır.

Nöral ve istatistiksel sınıflandırıcıları birleştiren bir yapı, Wilkinson ve arkadaşları [222] tarafından sunulmuştur. Önerdikleri yapı, nöral ve istatistiksel sınıflandırıcıların paralel bağlanmasıyla oluşan yapıya sadece belirsiz durumdaki örnekleri işleyen ikinci bir nöral sınıflandırıcının seri bağlanmasıyla oluşan entegre bir yapıdır (Şekil 5.15). Sonuçlar, böyle entegre bir yapının kullanımıyla sınıflandırma genel doğruluk değerlerinde %12 oranında bir iyileşme olacağını göstermiştir.



Şekil 5.15: Entegre sınıflandırma işlemi.

Schaale ve Furrer [223], yangından zarar görmüş bir bölgeye ait CASI (Compact Airbone Spectrographic Imager) görüntü verisini SOM kullanarak analiz etmiş ve elde edilen kümeler uçaklardan elde edilen renkli arazi haritaları kullanılarak sonuç arazi örtü sınıflarına atanmışlardır.

Benedictsson ve arkadaşları [224], YSA ve istatistik metotları hiper-spektral AVIRIS (Airborne Visible-Infrared Imaging Spectrometer) görüntü verilerine uygulamışlardır. İlk olarak verideki ilgilenilen özelliklerin çıkartılması ve aynı zamanda verinin boyutunun azaltılması için karar sınırları özellik çıkartımı metodu (Lee ve Landgrebe [225]) kullanılmıştır.

YSA'nın uzaktan algılama alanındaki uygulamaları pasif mikrodalga bölgesinde uzaktan algılama ölçümlerinden kar parametrelerinin [226], mikrodalga parlaklık sıcaklıklarının [227] ve bitki örtüsü kanopilerindeki radar saçılmalarının inversiyonlarına [228] yönelik çalışmalarda da başarıyla kullanılmıştır.

Dune ve arkadaşları, geri-yayılmalı ağlarda sınıflandırma problemlerinin çözümü için ağ başlangıç ağırlık değerlerini, lineer diskriminant fonksiyonları kullanarak belirlemişlerdir [229]. Aynı yaklaşım, hem ağırlıklar hem de ağ yapısı için German ve arkadaşları tarafından kullanılmıştır [230].

Uzaktan algılama verilerinin YSA ile sınıflandırılmasıyla ilgili olarak Paola ve Schowengerdt [180] tarafından yayınlanan bir makalede, geri yayılmalı MLP yapısına, giriş verisinin ön işlenmesi ve yapısı, YSA topolojisi, YSA'nın eğitimi, sonuç sınıfların oluşturulması, kodlama ve klasik sınıflandırma teknikleriyle karşılaştırma gibi sınıflandırma işleminin bütün elemanlarıyla ilgili genel bir bakış kapsamlı olarak sunulmuştur. Kanellopoulos ve arkadaşları [231], YSA mimarisi seçimi, optimizasyon algoritmalarının kullanımı, zenginleştirilmiş özellik kümelerinin kullanımı ve hibrid sınıflandırıcıların kullanımı üzerine kapsamlı bir çalışma yapmışlardır.

Mart 1997'de Uluslararası Uzaktan Algılama Birliği uzaktan algılamada YSA konulu özel bir sayı yayınlamıştır. Bu özel sayıda, uzaktan algılamada YSA konusuyla ilgili genel bilgiler ile YSA'nın uygulamalarından biri olan farklı yapıdaki verilerin beraber kullanımıyla ilgili bir çalışma Atkinson ve Tatnall tarafından sunulmuştur [14]. Ayrıca Benedictsson ve arkadaşlarının [15], [232], Kanellopoulos ve Wilkinson 'nun [231] sınıflandırma üzerine yaptığı deneysel çalışmalar da sunulmuştur. Sınıflandırma üzerine yapılan diğer bir çalışmada ise uzaktan algılama veri boyutunun, YSA yapısının, eğitim ve test verisi karakteristiklerinin sınıflandırma üzerine olan etkileri incelenmiştir [233].

Skidmore ve arkadaşları, hem spektral hem de uzaysal bilgilerin YSA'daki kullanımını incelemişlerdir [169]. Bu konu, Bruzzone ve arkadaşları [170], Kamata ve Kawaguchi [234] ile Paola ve Schowengerdt [21] tarafından da incelenmiştir.

Rollet ve arkadaşları [235], K-ortalımalı kontrolsüz kümeleme tekniğini kullanan RBF yapısıyla optik ve RADAR görüntülerini sınıflandırarak, RBF ve birleştirme-

ayırma tekniklerine dayalı otomatik bir kontrolsüz sınıflandırma algoritması geliştirmişlerdir.



6. UYGULAMA

6.1. Genel Bilgiler

Bu tez çalışmasının uygulama bölümünde kullanılacak YSA algoritmalarının seçiminde, literatürde daha çok görüntü sınıflandırma problemlerinin çözümünde yüksek performans veren algoritmaların göz önüne alınması ve bu algoritmaların sınıflandırma sonuçlarının birbirleriyle kıyaslanması esas alınmıştır. Tez çalışmasında kullanılan YSA algoritmalarından elde edilen sınıflandırma sonuçları, uzaktan algılama görüntülerinin sınıflandırılması problemlerinin çözümünde yaygın olarak kullanılan Maksimum Olabilirlik (MO) sınıflandırma algoritmasından elde edilen sonuçlar ile karşılaştırılmıştır. Maksimum Olabilirlik algoritmasından elde edilen sınıflandırma sonuçları, orijinal görüntü üzerinde seçilen sınıflara ait alıştırma bölgelerinin istatistiksel özelliklerine bağımlı olduğu halde YSA algoritmalarının ürettiği sonuçlar sınıflara ait alıştırma bölgelerinin istatistiksel özelliklerine bağımlı değildir. Bu tez çalışması süresince kullanılmış olan YSA mimari yapıları,

- MLP (Multi Layer Perseptron)
- RBF (Radial Basis Function)
- LVQ (Learning Vector Quantization)

dır. Bu mimari yapıların ele alınmasının temel nedeni; literatürde [197], [199], [219], [236], [170], [220], [235], [237] söz konusu YSA mimarilerinin kullandığı YSA eğitim algoritmalarının uzaktan algılamada kullanılan görüntülerin sınıflandırılması problemlerinin çözümünde klasik yöntemlerle kıyaslanabilir düzeyde yüksek performanslı sınıflandırma sonuçları sağlamalarıdır.

Tez çalışması boyunca, MLP mimarileri üzerinde kullanılmış olan geri yayımlı öğrenme algoritmaları şunlardır:

- Delta
- Delta Bar Delta (DBD)
- Geliştirilmiş Delta Bar Delta (EDBD)
- BFGS Kuasi-Newton (BFGS-KN)
- Eşleştirmeli Gradyent Powell-Beale (EGPB)
- Eşleştirmeli Gradyent Fletcher-Reeves (EGFR)
- Eşleştirmeli Gradyent Polak-Ribiere (EGPR)
- Tek Adım Sekant (TAS)
- Esnek Geri yayılma (EG)
- Ölçeklendirilmiş Eşleştirmeli Gradyent (ÖEG)

Kullanılmış olan RBF yapısı literatürde [118] tanımlandığı şekliyle kullanılmıştır. Tez çalışmasında uzaktan algılama görüntülerinin sınıflandırılması probleminde kullanılan RBF YSA mimarisi giriş katmanında, her biri sınıflandırmada kullanılmış olan 6 görüntü kanalına karşılık gelen giriş nöronu bulunmaktadır. RBF yapılarının karakteristik katmanı olarak tanımlanan Gauss fonksiyonu tabanlı PROTO katmanında bulunan nöron sayısının sınıflandırma performansı üzerine olan etkisinin incelenmesi için söz konusu karakteristik katmanda bulunan nöron sayıları sırasıyla 50,100 ve 200 nöron içerecek şekilde düzenlenmiştir. Bu şekilde hazırlanan RBF YSA mimari yapıları eğitilerek sınıflandırma kabiliyetleri araştırılmıştır. Kullanılmış olan RBF YSA yapılarının çıkış katmanında ise her biri hedeflenen sınıflardan birine ait olan ve YSA sınıflandırma tahmin değerini üreten 12 adet yapay nöron bulunmaktadır. Karakteristik katmanda bulunan nöron sayısının sınıflandırma performansı üzerindeki etkisinin incelenmesi amaçlandığından dizayn edilmiş olan RBF yapılarının tamamında RBF YSA hesap algoritmasında bulunan diğer tüm parametreler standart alınmıştır. Karşılaştırmaya esas olacak temel ağlar eğitilmeden önce bu parametrelerin optimal parametreler olması için farklı yapılarla denemeler yapılmıştır.

Kullanılmış olan LVQ yapısı, LVQ-1 ve LVQ-2 olarak bilinen klasik LVQ YSA yapısının geliştirilmiş türevleridir [118]. Uygulamada LVQ-1 ve LVQ-2 yapıları sağladıkları performans avantajından dolayı birlikte kullanılmıştır. Bir sınıflandırma ağı olan bu LVQ yapısının karakteristik katmanı olarak tanımlanan KOHONEN ara katmanında bulunan nöron sayıları her bir kategori için eşit sayıda referans vektörü ayrılacak şekilde oluşturulur. Uygulamada ara katman işlemci eleman sayısının sınıflandırma performansı üzerine olan etkisinin incelenmesi için söz konusu karakteristik katmanda bulunan nöron sayıları genel olarak literatürde de uygulanan her bir kategori için değişik sayıda referans vektörü kullanılarak belirlenir [236], [148]. Böylece KOHONEN ara katmanında bulunan nöron sayıları, toplam kategori sayısının 1'den 24'e kadar katları olarak 24 farklı yapıda düzenlenmiştir. Bu şekilde düzenlenen LVQ YSA mimari yapılarında daha önce yapılan testlerle optimal değerleri belirlenmiş olan parametreler sabit tutulmuş ve yapılar eğitilerek sınıflandırma performansları araştırılmıştır.

Tez çalışma verisi olarak kullanılan LANDSAT TM uydu görüntüsünün toplam 7 kanalından ısı kanal (6. kanal) dışındaki diğer kanalların, toplam 15 ikili kombinasyonu için olan saçılma grafikleri hazırlanmıştır. Literatüre uygun olarak özellik uzayının karakteristik yönlerini incelemek için hazırlanan saçılma grafikleri üzerine alıştırma paternleri, ortalama ve standart sapma değerlerine dayalı olarak tanımlanan dikdörtgen bloklarla işaretlenmiştir [71]. Bu blokların boyutları, alıştırma paternlerinin ortalama değerlerine standart sapma değerlerinin eklenip çıkarılmasıyla ($\mu + \sigma$ ve $\mu - \sigma$) hesaplanmıştır.

6.2. Kullanılan Donanım ve Yazılım Özellikleri

Bu tez çalışması kapsamında gerçekleştirilen YSA ve klasik istatistik Maksimum Olabilirlik karar kuralı tekniklerinin uzaktan algılama uydu görüntülerinin sınıflandırma problemine getirdikleri yaklaşımların karşılaştırılması amacını gerçekleştirmek için Erciyes Üniversitesi Mühendislik Fakültesi bünyesinde bulunan AutoCAD bilgisayar laboratuvarındaki 15 adet Pentium III işlemcili bilgisayar grubu kullanılmıştır. Bu performans karşılaştırmalarının maksimum düzeyde genellenebilir olmasını sağlamak için kullanılan her bir YSA mimarisi ve bu mimariler üzerindeki algoritmalar için çok sayıda test yapılmıştır. YSA'nın doğasında bulunan tesadüfîlik

ve probleme getirdiđi yaklaşımlar, katman sayısı, bu katmanlardaki yapay nöron sayısı ve öğrenme adım sayısı (epok) vb. parametrelere ve yaklaşımlara bağıldır. Bundan dolayı yapılan çalışmalara ait sonuçlar, katman sayısı, bu katmanlardaki yapay nöron sayısı ve epok sayısına göre çeşitlendirilmiştir.

Klasik Maksimum Olabilirlik sınıflandırma yöntemi literatürde açıklanan formüllere uygun olarak Matlab programı ortamında programlanmıştır [187], [69]. Yazılan programda, Maksimum Olabilirlik sınıflandırma kuralı öncül olasılıkların eşit olması durumuna göre düzenlenmiştir. Ayrıca bu tez çalışması içinde verilen tüm tablo, şekil ve grafiklerin oluşturulması da Matlab programı ortamında yazılan bilgisayar program kodları ile gerçekleştirilmiştir. YSA yapılarının sınıflandırma performanslarının analiz edilmesi işlemi Erciyes Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümü bünyesinde bulunan ve literatürde [238], [239] sınıflandırma amaçlı çalışmalarda da kullanılan NeuralWORKS Professional II programı ve Matlab programının sahip olduđu YSA algoritmaları ile gerçekleştirilmiştir.

6.3. Kullanılan Veri Modeli


Bu tez çalışması kapsamında kullanılmakta olan LANDSAT TM'e ait 7 kanallı çok spektrumlu uydu görüntü verisi, İstanbul Teknik Üniversitesi, İnşaat Fakültesi Jeodezi ve Fotogrametri Mühendisliği Bölümü Uzaktan Algılama Anabilim Dalı'ndan temin edilmiştir. Görüntü verisi ve algılayıcı sistemlerle ilgili ayrıntılar tezin ilgili bölümünde verilmiştir.

Çok spektrumlu görüntü verisinin YSA ve Maksimum Olabilirlik yöntemleriyle sınıflandırılmasında ısı kanal olan 6. kanal kullanılmamıştır. Veri, sınıflandırıcıya tek tek piksel bazında verilmiş ve sonuçta 12 sınıftan birisine girmeye zorlanmıştır. Maksimum Olabilirlik yönteminde piksel paterni, en yakın olasılığa sahip olduđu (en yüksek Gauss olasılık yoğunluk değerini aldığı) sınıfa atanırken YSA yapısında Kazanan Hepsini Alır (Winner Takes All) yöntemine uygun olarak en yüksek değerin alındığı çıkış katmanı yapay nöronunun temsil ettiđi sınıfa atanmıştır.

6.4. Çalışma Alanı

Bu tez çalışmasında, İstanbul ilinin, Avrupa yakası kısmında bulunan Güngören, Gaziosmanpaşa, Esenler, Bayrampaşa, Bağcılar ve Küçükçekmece ilçelerini içeren yaklaşık 18 km x 18 km genişliğindeki bir alan, çalışma alanı olarak seçilmiştir. Özellikle bu alanın seçilmesinde, bölgenin sahip olduğu farklı uzaysal frekans özelliği etkin olmuştur. Literatürde de görüldüğü gibi, YSA ile gerçekleştirilecek arazi sınıflandırmasında, YSA'nın Maksimum Olabilirlik yöntemiyle sınıflandırma performanslarının karşılaştırılmasına ek olarak, YSA'nın farklı uzaysal frekansa sahip alanlardaki sınıflandırma performansının da değerlendirilmesi mümkün olabilmektedir [240].

Bu alana ait çok spektrumlu uydu görüntü verisi LANDSAT TM algılayıcısından 15 Temmuz 1998 tarihinde elde edilmiştir (Şekil 6.1). Görüntü verisi toplam 6 kanaldan (ısıl kanal 6 hariç) ve 600 x 600 pikselden oluşmaktadır.



Şekil 6.1: Çalışma alanı (LANDSAT TM, RGB: 3/2/1 doğal renkli uydu görüntüsü) ve eğitim alanları.

6.5. Eğitim ve Test Alanlarının Seçimi

Çalışma alanı öncelikle ISODATA (Iterative Self Organizing Data) algoritmasıyla kontrolsüz olarak sınıflandırılmıştır [241], [242], [243]. Elde edilen 15 sınıf, bölgenin hava fotoğraflarından yararlanılarak 12 sınıfa indirgenmiştir. ISODATA sınıflandırılmış görüntüsü ve bölgeye ait mevcut 1/5000 ölçekli hava fotoğraflarından yararlanılarak eğitim ve test alanları poligon vektörler kullanılarak seçilmiştir (Şekil 6.1). Hedef sınıfları en iyi derecede temsil edecek ve olabildiğince homojen yapıda seçilen eğitim veri kümesi toplam 2434 patern içermektedir. Sınıflandırma performansının istatistiksel olarak yansız bir şekilde değerlendirilebilmesi için kullanılan test verisi, eğitim verilerinden farklı yerlerde belirlenen toplam 3568 paternden oluşmuştur. Tablo 6.1, Tablo 6.2 ve Tablo 6.3’de sırasıyla, seçilen sınıfların özellikleri ile eğitim ve test alanlarının sınıf istatistikleri verilmektedir.

Tablo 6.1: Sınıf özellikleri.

Sınıf Adı	Sınıf Kodu	Açıklama
Yeşil 1	1	Bitki örtüsünün çok yoğun olduğu orman bölgeleri
Yeşil 2	2	Bitki örtüsü yoğunluğunun az olduğu çayır tipi alanlar
Yeşil 3	3	Bitki örtüsü yoğunluğunun çok az olduğu açık zeminler
Toprak 1	4	Çıplak toprak
Toprak 2	5	Tarla tipi çıplak toprak
Toprak 3	6	Kazılmış ve taş ocağı alanları
Yol 1	7	TEM yolu
Yol 2	8	Ara yollar
Yerleşim 1	9	Düzenli yerleşim alanları
Yerleşim 2	10	Düzensiz yerleşim alanları
Sanayi	11	Organize sanayi ve büyük fabrika alanları
Su	12	Göl ve baraj göletleri

Tablo 6.2: Eğitim piksellerinin istatistiksel özellikleri.

Sınıf	Piksel Sayısı	ORTALAMA						STANDART SAPMA					
		Kanal						Kanal					
		1	2	3	4	5	6	1	2	3	4	5	6
1	295.00	57.17	23.75	20.14	66.17	50.75	17.58	1.86	1.76	1.57	12.83	9.61	3.24
2	292.00	63.41	27.12	24.66	92.42	65.72	24.17	2.50	1.16	3.82	35.05	7.94	6.67
3	162.00	69.69	31.82	33.09	77.58	90.20	37.65	2.86	2.3	3.63	8.46	11.71	5.49
4	99.00	161.1	92.53	120.29	115.29	181.73	105.83	26.98	16.89	22.61	18.67	29.94	19.72
5	105.00	67.18	27.16	29.00	35.74	58.86	29.52	1.41	0.5	0.65	1.54	1.67	1.27
6	152.00	110.48	49.92	56.99	47.95	63.60	40.43	13.41	8.06	9.92	8.92	14.24	9.32
7	202.00	94.24	40.93	46.33	47.21	63.58	35.50	7.06	3.95	5.18	4.90	7.82	4.91
8	141.00	102.43	54.77	67.70	81.72	110.17	59.10	12.07	8.42	13.13	16.56	23.51	12.99
9	232.00	97.75	45.56	55.56	52.35	83.39	54.79	5.88	3.56	4.68	5.51	7.57	4.55
10	132.00	104.31	53.22	67.05	75.21	114.79	70.08	14.08	8.63	11.38	6.49	10.36	8.15
11	452.00	127.66	65.02	81.87	72.39	122.37	82.27	19.74	11.99	14.21	12.39	18.81	13.41
12	167.00	57.33	21.3	17.23	10.09	7.25	4.48	1.44	0.63	0.71	2.00	4.30	1.59


Tablo 6.3: Test piksellerinin istatistiksel özellikleri.

Sınıf	Piksel Sayısı	ORTALAMA						STANDART SAPMA					
		Kanal						Kanal					
		1	2	3	4	5	6	1	2	3	4	5	6
1	722.00	56.60	24.50	19.90	70.90	53.00	18.30	1.96	2.35	1.62	18.63	10.88	3.54
2	389.00	64.60	26.70	26.80	58.40	66.40	27.60	2.06	1.29	1.94	5.21	5.72	3.02
3	242.00	69.00	31.10	34.00	71.20	90.90	38.20	2.83	1.94	2.38	7.62	6.18	3.53
4	103.00	145.60	86.90	118.60	114.10	184.40	106.20	20.18	13.54	20.34	16.47	29.87	18.56
5	160.00	66.70	27.20	29.40	37.60	60.00	30.40	1.60	0.90	1.27	6.32	2.74	2.57
6	134.00	104.60	47.40	54.40	46.40	61.90	39.00	11.81	7.51	9.79	9.72	15.16	9.66
7	131.00	87.70	38.00	42.90	47.70	59.50	33.40	3.67	1.99	2.86	6.33	7.51	3.66
8	100.00	109.60	61.70	79.40	95.30	131.30	70.70	12.20	8.98	14.20	10.94	20.81	14.96
9	323.00	99.40	46.30	56.40	52.30	83.50	54.90	5.61	3.36	4.44	4.61	6.68	4.44
10	296.00	104.20	52.50	64.80	78.10	112.60	66.50	14.60	8.59	11.19	10.15	10.90	7.49
11	477.00	127.30	65.40	83.00	75.40	126.00	83.10	27.94	16.58	20.01	16.63	20.84	14.36
12	571.00	56.20	19.80	16.00	9.20	5.80	3.90	1.68	1.63	1.62	0.66	1.77	1.10


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 çizdirilmiş ve sınıf değerleri, standart sapmalarının ortalama değerlerinden çıkarılması ve ortalama değerlerine eklenmesiyle sınırları belirlenen dikdörtgen vektörlerle saçılım grafikleri üzerine işaretlenmiştir. 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 6 kanalın bütün ikili kombinasyonlarında grafik olarak hazırlanmıştır. Bu grafiklerin analizinde, iki boyutlu tüm özellik uzaylarında özellikle 8. ve 10. sınıfların arasındaki örtüşme dikkat çekicidir. 6. ve 7. sınıflardaki ayırt edilebilirlik derecesi, 8. ve 10. sınıflardaki kadar düşük seviyede olmamakla beraber, bu sınıflarda da

sınıflandırma performanslarının zayıf çıkması beklenmektedir (Şekil 6.2 ve Şekil 6.3). Grafik irdelemede zayıf ayırt edilebilirlik derecesine sahip olan bu sınıfların durumları, dönüştürülmüş diverjans analiziyle sayısal olarak daha objektif bir şekilde analiz edilebilir [71]. Ayrıca bunların ve diğer sınıfların kendi sınıflandırma performansları ve global sınıflandırma performansına olan etkileri, iki boyutlu özellik uzaylarının sınıflandırma sonrası sınıf karar bölgelerinde de analiz edilecektir.


Ayrıca 3. ve 4. kanalların oluşturduğu iki boyutlu özellik uzayı baz alınarak bu özellik uzayındaki her bir sınıf için logaritmik olasılık yoğunluk grafiği (diskriminant fonksiyonu) hesaplanmıştır. Daha sonra özellik uzayının her bir sınıf için aldığı diskriminant fonksiyon değerleri, sınıfların birbirlerine göre karşılaştırılabilmesini sağlamak amacıyla aynı ölçeklemeye tabi tutulmuştur. Grafiklerde renk paletinde sarıdan siyaha gidildikçe diskriminant fonksiyon değerleri maksimuma yaklaşmaktadır. Bu grafiklerle her bir sınıfın ilgili özellik uzayındaki dağılımı ve elde ettiği olasılık yoğunluk değerlerinin seviyesi diğer sınıflarla karşılaştırmalı olarak görülebilmektedir. Özellikle, bütün sınıflar içinde bağıl olarak daha yüksek bir varyans değerinden dolayı 8. sınıfa ait yoğunluk değerleri diğer sınıfların değerlerine göre bağıl olarak daha düşüktür. Grafiklerde görüldüğü üzere, varyansı küçük olan sınıflar daha büyük yoğunluk değeri almışlardır. 8. sınıf bu kanallarda pozitif yüksek bir korelasyon gösterirken 10. sınıf ile olan karışımı burada da görülebilmektedir (Şekil 6.4 ve Şekil 6.5).




Şekil 6.2: İki boyutlu özellik uzayları ve alıştırma paternlerinin bu uzaylardaki dağılımları.



Şekil 6.3: İki boyutlu özellik uzayları ve alıştırma paternlerinin bu uzaylardaki dağılımları.



Şekil 6.4: Sınıf alıştırma verilerinin iki boyutlu özellik uzayındaki logaritmik Normal olasılık yoğunluk dağılımları.



Şekil 6.5: Sınıf alıştırma verilerinin iki boyutlu özellik uzayındaki logaritmik Normal olasılık yoğunluk dağılımları.

Oluşturulan sınıf alıştırma örneklerinin 6 boyutlu özellik uzayındaki ayrılabilirlik analizi, kantitatif olarak da incelenmiştir. Bu amaçla sınıf örnek alanlarının 6 kanal için diverjans ve dönüştürülmüş diverjans değerleri hesaplanmıştır. Literatürde diverjans değerlerine göre, optimal olmayan özellik uzayı değerlerinden dolayı yanlış karar verilebileceğinden özellikle dönüştürülmüş diverjans değerlerinin kullanımı önerilmektedir [71]. Literatürde, dönüştürülmüş diverjans değerlerinin derecelendirilmesine göre 2000-1900 arası çok iyi seviyede bir diskriminant derecesini, 1900-1700 arası iyi ve 1700 den küçük ise zayıf bir ayırım derecesini göstermektedir [69]. Bu değerlerin hesaplanması için yazılan bilgisayar programı verilen derecelendirmeye uygun olarak dönüştürülmüş diverjans değerlerini kullanarak sınıfların hangi ayrılabilirlik seviyesine girdiğini belirtmektedir. Bu derecelendirmeye göre; zayıf ayrılabilirlik derecesine hiçbir sınıf girmemektedir. Grafik analizde belirli özellik uzaylarında birbiri üzerine bindiren 8., 10., 6. ve 7. sınıflar dönüştürülmüş diverjans analizinde en düşük ayrılabilirlik derecesi göstermektedir. Özellikle 8. ve 10. sınıfların ayırım derecesi zayıf seviyesine çok

yakındır. Diverjans ve dönüştürülmüş diverjans değerleri, Tablo 6.4 ve Tablo 6.5’de verilmiştir.

Tablo 6.4: Diverjans değerleri.

Sınıf	1	2	3	4	5	6	7	8	9	10	11	12
1	0.0	42.2	71.9	4590.9	428.9	1393.6	516.7	1006.2	799.6	1077.7	2492.5	1051.1
2	42.2	0.0	82.8	2916.5	978.3	1453.5	334.8	554.8	527.4	558.7	2091.3	3162.6
3	71.9	82.8	0.0	2576.9	812.5	1076.9	345.8	506.7	391.8	447.5	1441.4	993.8
4	4590.9	2916.5	2576.9	0.0	29598.0	126.1	253.8	28.5	152.2	55.6	28.5	17412.0
5	428.9	978.3	812.5	29598.0	0.0	2999.1	1120.3	5851.9	2230.2	5472.8	9890.2	1441.1
6	1393.6	1453.5	1076.9	126.1	2999.1	0.0	19.6	120.7	26.9	85.7	38.2	2831.2
7	516.7	334.8	345.8	253.8	1120.3	19.6	0.0	69.5	25.5	73.2	97.4	1474.7
8	1006.2	554.8	506.7	28.5	5851.9	120.7	69.5	0.0	38.7	16.0	101.8	4092.6
9	799.6	527.4	391.8	152.2	2230.2	26.9	25.5	38.7	0.0	26.8	42.8	2597.5
10	1077.7	558.7	447.5	55.6	5472.8	85.7	73.2	16.0	26.8	0.0	57.3	4331.4
11	2492.5	2091.3	1441.4	28.5	9890.2	38.2	97.4	101.8	42.8	57.3	0.0	7623.2
12	1051.1	3162.6	993.8	17412.0	1441.1	2831.2	1474.7	4092.6	2597.5	4331.4	7623.2	0.0

Tablo 6.5: Dönüştürülmüş diverjans değerleri.

Sınıf	1	2	3	4	5	6	7	8	9	10	11	12
1	0.0	1992.3	1999.8	2000.0	2000.0	2000.0	2000.0	2000.0	2000.0	2000.0	2000.0	2000.0
2	1992.3	0.0	2000.0	2000.0	2000.0	2000.0	2000.0	2000.0	2000.0	2000.0	2000.0	2000.0
3	1999.8	2000.0	0.0	2000.0	2000.0	2000.0	2000.0	2000.0	2000.0	2000.0	2000.0	2000.0
4	2000.0	2000.0	2000.0	0.0	2000.0	2000.0	2000.0	1953.3	2000.0	1997.7	1972.4	2000.0
5	2000.0	2000.0	2000.0	2000.0	0.0	2000.0	2000.0	2000.0	2000.0	2000.0	2000.0	2000.0
6	2000.0	2000.0	2000.0	2000.0	2000.0	0.0	1803.5	2000.0	1938.5	1999.9	1992.8	2000.0
7	2000.0	2000.0	2000.0	2000.0	2000.0	1803.5	0.0	1999.7	1923.0	1999.7	2000.0	2000.0
8	2000.0	2000.0	2000.0	1953.3	2000.0	2000.0	1999.7	0.0	1986.1	1725.7	2000.0	2000.0
9	2000.0	2000.0	2000.0	2000.0	2000.0	1938.5	1923.0	1986.1	0.0	1951.6	1995.2	2000.0
10	2000.0	2000.0	2000.0	1997.7	2000.0	1999.9	1999.7	1725.7	1951.6	0.0	1997.6	2000.0
11	2000.0	2000.0	2000.0	1972.4	2000.0	1992.8	2000.0	2000.0	1995.2	1997.6	0.0	2000.0
12	2000.0	2000.0	2000.0	2000.0	2000.0	2000.0	2000.0	2000.0	2000.0	2000.0	2000.0	0.0

6.6. Maksimum Olabilirlik Sınıflandırma Uygulaması

Bölüm 6’da detaylı bir şekilde açıklanan Maksimum Olabilirlik karar kuralı, her bir sınıfın Gauss olasılık yoğunluk fonksiyonunun 2. derece istatistiklerine dayanan parametrik bir sınıflandırma tekniğidir. Eğer sınıf dağılımları gerçekten normal dağılıma uyuyorsa Maksimum Olabilirlik karar kuralı en optimal yöntemdir. Her sınıfın temel diskriminant fonksiyonu;

$$d_i(X) = p(X | w_i) p(w_i) = \frac{p(w_i)}{(2\pi)^{n/2} |C_i|^{1/2}} e^{-(1/2)(X-U_i)^T \Sigma^{-1} (X-U_i)} \quad (6.1)$$

olarak verilir. Burada n, kanal sayısı, X, veri vektörü, U_i, i sınıfının ortalama vektörü ve C_i, i sınıfının kovaryans matrisidir. Ortalama vektörü ve kovaryans matrisi elemanları yansız karakterli olarak eğitim verisinden hesaplanır.

$$X = \begin{bmatrix} x_{i1} \\ \vdots \\ x_{in} \end{bmatrix} \quad (6.2)$$

$$U_i = \begin{bmatrix} \mu_{i1} \\ \vdots \\ \mu_{in} \end{bmatrix} \quad (6.3)$$

$$C_i = \begin{bmatrix} \sigma_{i11} & \sigma_{i12} & \cdots & \sigma_{i1n} \\ \sigma_{i21} & \sigma_{i22} & \cdots & \sigma_{i2n} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{in1} & \sigma_{in2} & \cdots & \sigma_{inn} \end{bmatrix} \quad (6.4)$$

$$\mu_{ij} = \frac{1}{P_i} \sum_{l=1}^{P_i} x_{jl}, \quad j = 1, 2, \dots, n \quad (6.5)$$

$$\sigma_{ijk} = \frac{1}{P_i - 1} \sum_{l=1}^{P_i} (x_{jl} - \mu_{ij})(x_{kl} - \mu_{ik}), \quad j = 1, 2, \dots, n \quad \text{ve} \quad k = 1, 2, \dots, n \quad (6.6)$$


Burada P_i, i. sınıftaki eğitim elemanı sayısıdır. Bu sayı kovaryans matrisinin hesaplanabilmesi için, veri boyutundan en az bir fazla olmalıdır. Yukarıdaki eşitliğin logaritmik bir fonksiyondan geçirilmesi ve sabit π sayısının ihmal edilmesiyle, diskriminant fonksiyonu;

$$d_i(X) = \ln p(w_i) - \frac{1}{2} \ln |C_i| - \frac{1}{2} (X - U_i)^T C^{-1} (X - U_i) \quad (6.7)$$


olur. Eğer sınıf öncül olasılıkları eşit kabul edilirse, 1.terim sabit olur ve ihmal edilebilir. 2. terimde her bir sınıf için aynı olduğundan sınıflandırma işlemi sırasında her bir piksel için sadece 3. terim hesaplanacaktır. Diskriminant değeri $d_i(X)$ her bir sınıf için hesaplanır ve hedef piksel, en fazla olasılığa sahip olduğu (diskriminant fonksiyon değerinin en büyük olduğu) sınıfa atanır.

Yukarıdaki formülasyona ve işlem akış sırasına göre Maksimum Olabilirlik sınıflandırma yöntemi için bir program yazılmıştır. Bu programla Maksimum Olabilirlik tekniğiyle görüntünün sınıflandırılmasına ek olarak istenen özellik uzayı da sınıflandırılabilmekte ve sınıf aposteriori olasılıkları ve bu olasılıkların istenen sınıf için olan değerleri ayrı ayrı elde edilebilmektedir. Sınıflandırma hata matrisleri de bu kodla hesaplanabilmektedir.

Bu programla LANDSAT TM'den elde edilen İstanbul'un İkitelli bölgesine ait olan uzaktan algılanmış görüntüsü 6 kanallı olarak sınıflandırılmış ve bütün kategorilerin apriori olasılıkları eşit alınmıştır. Kullanılan sınıflandırma lejantı Şekil 6.6'de verilmiştir. Bu lejant bütün sınıflandırma uygulamaları için kullanılmıştır. Buna uygun olarak Şekil 6.7'te Maksimum Olabilirlik sınıflandırma yönteminden elde edilen sınıflandırılmış görüntü verilmektedir. Sınıflandırma performans değerlerinin ölçütü olarak kullanılacak hata matrisleri de aynı programla hazırlanmıştır. Maksimum Olabilirlik sınıflandırma yönteminin alıştırma ve test alanları için elde ettiği hata matrisleri Tablo 6.6 ve Tablo 6.7'de verilmektedir. Bu tablolardaki kısaltmalardan KD kullanıcı doğruluğunu, ÜD üretici doğruluğunu, GD bütün sınıflandırmanın genel doğruluğunu ve TP ise toplam piksel sayısını göstermektedir. Eğitim verisi için genel doğruluk %94.1 ve Kappa istatistik değeri %93.4 olarak hesaplanırken, sınıflandırma performans değerlendirmesinin literatüre göre yansız olması için kullanılan test verisinden elde edilen genel doğruluk değeri ise %84.9 ve Kappa değeri %83.0 olarak elde edilmiştir.



Şekil 6.6: Renk lejantı.



Şekil 6.7: Maksimum Olabilirlik yönteminden elde edilen sınıflandırılmış görüntü.

Tablo 6.6: MO yöntemine göre eğitim verisi hata matrisi (GD=% 94.1 ve Kappa=% 93.4).

		REFERANS VERİ													
SINIFLANDIRILMIŞ VERİ	Sınıf	1	2	3	4	5	6	7	8	9	10	11	12	TP	KD
	1	293	2	0	0	0	0	0	0	0	0	0	0	295	99.3
	2	0	272	20	0	0	0	0	0	0	0	0	0	292	93.2
	3	0	1	163	0	0	0	0	1	0	0	0	0	165	98.8
	4	0	0	0	96	0	0	0	2	0	0	1	0	99	97.0
	5	0	0	0	0	105	0	0	0	0	0	0	0	105	100
	6	0	0	0	0	0	142	8	1	0	0	1	0	152	93.4
	7	0	0	0	0	0	14	183	2	3	0	0	0	202	90.6
	8	0	0	0	7	0	6	3	111	9	5	0	0	141	78.7
	9	0	0	0	0	0	1	1	5	217	4	4	0	232	93.5
	10	0	0	0	1	0	0	0	8	0	123	0	0	132	93.2
	11	0	0	0	7	0	0	0	4	20	2	419	0	452	92.7
	12	0	0	0	0	0	0	0	1	0	0	0	166	167	99.4
TP		293	275	183	111	105	163	195	135	249	134	425	166	2434	
ÜD		100	98.9	89.1	86.5	100	87.1	93.8	82.2	87.1	91.8	98.6	100		


Tablo 6.7: MO yöntemine göre test verisi hata matrisi (GD=% 84.9 ve Kappa=83.0).

	Sınıf	REFERANS VERİ												TP	KD
		1	2	3	4	5	6	7	8	9	10	11	12		
SINIFLANDIRILMIŞ VERİ	1	696	23	2	0	0	0	0	1	0	0	0	0	722	96.4
	2	2	292	95	0	0	0	0	0	0	0	0	0	389	75.1
	3	0	36	195	0	0	0	0	11	0	0	0	0	242	80.6
	4	0	0	0	83	0	0	0	19	0	0	1	0	103	80.6
	5	0	38	0	0	118	0	4	0	0	0	0	0	160	73.8
	6	0	0	0	0	0	110	15	1	7	0	1	0	134	82.1
	7	0	0	0	0	0	2	122	5	2	0	0	0	131	93.1
	8	0	0	0	15	0	0	0	77	0	8	0	0	100	77.0
	9	0	0	0	0	0	0	5	5	310	0	3	0	323	96.0
	10	0	0	2	4	0	0	0	67	5	209	9	0	296	70.6
	11	0	0	0	35	0	1	0	18	20	37	366	0	477	76.7
	12	0	0	0	0	0	50	0	3	0	0	0	518	571	90.7
TP		698	389	294	137	118	163	146	207	344	254	380	518	3648	
ÜD		99.7	75.1	66.3	60.6	100	67.5	83.6	37.2	90.1	82.3	96.3	100		

Sınıflandırma sonucunda 8 nolu sınıfa ait doğruluk değerinin hem eğitim verisi hem de test verisi için olan hata matrislerinde düşük çıktığı görülmektedir. Referans verisinde 8 nolu sınıfa ait olan piksellerden bu sınıfa doğrulukla atanan piksellerin dışında, hatalı olarak diğer sınıflara atanan piksellerin çoğu 10 nolu sınıfa atanmışlardır. Daha önce gerçekleştirilen ayırt edilebilirlik analizlerinde de en düşük değerler 8 ve 10 nolu sınıflar arasında elde edilmiştir. Sınıflandırma görüntüsünün 1/5000 ölçekli hava fotoğraflarıyla karşılaştırılmasından özellikle 8 nolu sınıfın 1, 7, 11 ve 12 nolu sınıflar dışındaki diğer sınıflarla karıştığı gözlenmektedir. Özellikle 3 ve 10 nolu sınıflarla büyük oranda karışmaktadır. Bu sınıflarla olan ortalama değerleri birbirine yakın ve standart sapma değerleri ise daha büyüktür. 7 nolu sınıfta olması gerektiğinden biraz daha büyük oluşmuştur. Özellikle 6 nolu sınıfın çevresindeki bölgelerde hatalı oluşmuştur. Ayrıca 12 nolu sınıfın test verisi üretici doğruluk değeri tam doğru olmasına karşın görüntünün doğusunda yer alan Alibeyköy baraj göletinin kuzey devamındaki su kitlesi 8 nolu sınıfa atanmıştır. Bu durum MO yönteminin her bir sınıf için ayrı ayrı belirlenen istatistiksel parametreleri diğer sınıflardan bağımsız olarak kullandığı gerçeğini desteklemektedir.

Test verisi genel sınıflandırma doğruluğunun eğitim verisinden oldukça düşük çıkması MO yönteminin eğitim verisine bağımlı olarak tanımladığı sınıflar arası ayırt edilebilirlik ilişkilerinin (karar sınırları) eğitim sırasında kullanılmayan görüntünün diğer bölgeleri için fazlasıyla genel olmadığını göstermektedir. Özellikle bu durum, YSA uygulamalarının vereceği sonuçlarla kıyaslanarak hangi yaklaşımın daha iyi bir genelleme yeteneğine sahip olacağını gösterecektir.

MO yönteminin 3. ve 4. kanalların oluşturduğu iki boyutlu özellik uzayı için ürettiği karar bölgeleri Şekil 6.8’de verilmektedir. Gerçekleştirilen bu sınıflandırma işleminin eğitim verisi GD değeri %82.9 ve test verisi GD değeri %81.1’dir. Bu işlem için elde edilen test verisi hata matrisine göre en düşük performans 8, 10 ve 11 nolu sınıflarda gerçekleşmiştir. 8 nolu sınıf 4 ve 10 nolu sınıflarla, 10 nolu sınıf 8 nolu sınıfla ve 11 nolu sınıf da 4, 6, 9 ve 10 nolu sınıflarla karışmıştır. Şekilde de görüldüğü gibi 8 nolu sınıf iki boyutlu özellik uzayı üzerinde baskın bir görünüm sergilemektedir.



Şekil 6.8: Maksimum Olabilirlik yönteminin ürettiği karar sınırları.

6.7. Yapay Sinir Ağları Uygulaması

Bu tez çalışması kapsamındaki MLP YSA uygulamalarından EDBD öğrenme algoritması dışındaki diğer algoritmalar için ara katmanlarda literatürde de çok spektrumlu uydu görüntü verilerinin sınıflandırılması için kullanılan ve daha iyi sonuçlar verdiği belirtilen TANH (tanjant hiperbolik) aktivasyon fonksiyonu kullanılmıştır [176], [215]. EDBD algoritması için ara katmanda sigmoid aktivasyon fonksiyonu kullanılmıştır. Çıkış katmanlarında ise Delta, DBD ve EDBD algoritmaları için “softmax” aktivasyon fonksiyonu ve diğer MLP algoritmaları içinde yine TANH fonksiyonu kullanılmıştır (Tablo 6.8). RBF YSA yapısının

karakteristik ara katmanı olan PROTO katmanında radyal tabanlı Gauss aktivasyon fonksiyonu ve çıkış katmanında da TANH fonksiyonu kullanılmıştır. Çok spektrumlu giriş verisi lineer olarak $[-1 + 1]$ kapalı aralığına ölçeklenmiştir [176]. Giriş verisinin ölçeklenmesiyle veri yapısı, YSA içindeki karakteristik hesaplama tekniğine daha uygun bir hale getirilmiş ve işlemsel etkinliğinin artırılması amaçlanmıştır. Uygulamada ham verinin normalize edilmesinin YSA yakınsama hızını arttırdığı gösterilmiştir [169]. Tüm görüntü verisi de eğitim verisinin normalize edildiği $[-1 + 1]$ aralığına ölçeklenmiştir. Bu aralığın seçilmesinde, YSA aktivasyon fonksiyonu olarak veriyi $[-1 + 1]$ arasına sıkıştıran tanjant hiperbolik (TANH) fonksiyonunun kullanılmış olmasının yanında, literatüre göre $[0 + 1]$ kapalı aralığına çekilen veride meydana gelen birbirine yakın komşu değerler arasındaki duyarlılık kaybının, bu aralığın iki katına çıkarılarak azaltılmaya çalışılması da etken olmuştur [188].


Tablo 6.8: MLP YSA yapısı öğrenme algoritmalarında kullanılan aktivasyon fonksiyonları.

ÖĞRENME KURALI	1. ARA KATMAN	2. ARA KATMAN	ÇIKIŞ KATMANI
Delta	Tanh	Tanh	Softmax
DBD	Tanh	Tanh	Softmax
EDBD	Sigmoid	Sigmoid	Softmax
EGPB	Tanh	Tanh	Tanh
EGFR	Tanh	Tanh	Tanh
EGPR	Tanh	Tanh	Tanh
EG	Tanh	Tanh	Tanh
TAS	Tanh	Tanh	Tanh
BFGS	Tanh	Tanh	Tanh
ÖEG	Tanh	Tanh	Tanh

Bu çalışmada daha önce tezin giriş ve beşinci bölümlerinde de belirtilen YSA mimari yapıları ve öğrenme algoritmaları, uzaktan algılama görüntü verilerinin sınıflandırılması için kullanılmıştır. Yapılan her bir YSA sınıflandırma uygulaması hem kendi içinde hem de literatürde yaygın olarak kullanılan ve genel kabul görmüş klasik Maksimum Olabilirlik sınıflandırma yönteminin sonuçlarıyla karşılaştırılmıştır.

Görüntü verilerinin YSA ile sınıflandırılmasında izlenen aşamalar aşağıdaki akış şemasında gösterilmektedir (Şekil 6.9). İlk aşamada uydu görüntü verisinin sayısal değerleri MultiSpec programı aracılığıyla matris olarak elde edilmiştir. Bu işlem yardımıyla görüntü verisinin orijinal parlaklık değerleri üzerinde hiçbir değişme

olmamıştır. Tüm görüntü ve belirlenen eğitim ve test alanlarına ait paternler YSA'da işlenmeye uygun hale getirilmiştir.



Şekil 6.9: YSA ile sınıflandırmada hesap akış şeması.

Kullanılan bütün YSA mimari ve öğrenme algoritmalarında giriş katmanı, kullanılan her bir kanala karşılık bir yapay nöron gelecek şekilde 6 nöron olarak tesis edilmiştir. YSA giriş verisi $[-1 +1]$ kapalı aralığına lineer olarak ölçeklenmiştir. Çıkış katmanı da hedeflenen 12 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 (Tablo 6.9).

Tablo 6.9: YSA çıkışının veri yapısı.

Sınıf	Çıkış Veri Yapısı											
1	1	0	0	0	0	0	0	0	0	0	0	0
2	0	1	0	0	0	0	0	0	0	0	0	0
3	0	0	1	0	0	0	0	0	0	0	0	0
4	0	0	0	1	0	0	0	0	0	0	0	0
5	0	0	0	0	1	0	0	0	0	0	0	0
6	0	0	0	0	0	1	0	0	0	0	0	0
7	0	0	0	0	0	0	1	0	0	0	0	0
8	0	0	0	0	0	0	0	1	0	0	0	0
9	0	0	0	0	0	0	0	0	1	0	0	0
10	0	0	0	0	0	0	0	0	0	1	0	0
11	0	0	0	0	0	0	0	0	0	0	1	0
12	0	0	0	0	0	0	0	0	0	0	0	1

YSA ara katman sayısı ve bu katmanlardaki yapay nöron sayısının uzaktan algılanmış görüntülerin sınıflandırma problemine en iyi yakınsamayı getirecek optimal değerleri literatüre göre ve deneme yanılma yöntemiyle belirlenmeye çalışılmıştır [187]. Bu öncül analizlerden sonra tüm MLP YSA mimari yapılarında kullanılan algoritmalarda yapay nöron sayısı, tek ara katmanlı ağlarda sırasıyla 12, 15, 18, 24 ve 30 nöron olarak ve iki ara katmanlı ağlarda ise 12-12, 9-15, 12-24, 18-24 ve 24-30 olarak belirlenmiştir (Tablo 6.10). RBF yapıların karakteristik ara katmanı olan PROTO katmanında sırasıyla 50 100 ve 200 nöron kullanılmıştır. Ayrıca değiştirilmiş RBF yapısında da PROTO ara katmanı 50 ve ikinci ara katman 18 nöron olarak dizayn edilmiştir (Tablo 6.11). LVQ YSA yapılarının karakteristik ara katmanı olan KOHONEN katmanındaki işlemci eleman sayısı ise literatüre uygun olarak toplam sınıf sayısının 1'den 24'e kadar olan sayma sayılarının katları alınarak belirlenmiştir. Böylece ara katman işlemci eleman sayısı 12, 24, 36, 48, 60, 72, 84, 96, 108, 120, 132, 144, 156, 168, 180, 192, 204, 216, 228, 240, 252, 264, 276, 288 olarak düzenlenmiştir (Tablo 6.12).

Tablo 6.10: MLP yapılarının mimari özellikleri.

YAPI NO	NÖRON SAYISI			
	GirişKatmanı	1. Ara Katman	2. AraKatman	ÇıkışKatmanı
1	6	12	-	12
2	6	15	-	12
3	6	18	-	12
4	6	24	-	12
5	6	30	-	12
6	6	9	15	12
7	6	12	24	12
8	6	18	24	12
9	6	24	30	12

Tablo 6.11: RBF yapılarının mimari özellikleri.

YAPI NO	NÖRON SAYISI			
	GirişKatmanı	1. AraKatman	2. AraKatman	ÇıkışKatmanı
1	6	50	-	12
2	6	100	-	12
3	6	200	-	12
4	6	50	18	12

Tablo 6.12: LVQ yapılarının mimari özellikleri.

YAPI NO	NÖRON SAYISI		
	GirişKatmanı	Ara Katman	Çıkış Katmanı
1	6	12	12
2	6	24	12
3	6	36	12
4	6	48	12
5	6	60	12
6	6	72	12
7	6	84	12
8	6	96	12
9	6	108	12
10	6	120	12
11	6	132	12
12	6	144	12
13	6	156	12
14	6	168	12
15	6	180	12
16	6	192	12
17	6	204	12
18	6	216	12
19	6	228	12
20	6	240	12
21	6	252	12
22	6	264	12
23	6	276	12
24	6	288	12

Eğitim ve test verileri dizisel bir sıralanışla homojen olarak oluşturulmuştur. Ön hazırlık aşamasından sonra ağın eğitimine başlanmıştır. Ağın serbest parametrelerinin (ağırlık ve bias) güncellenmesi, bütün eğitim veri kümesinin ağda işlenmesinden sonra parametreleri güncelleyen toplu eğitim (batch traininig) yöntemine göre yapılmıştır [188]. Eğitim verisinin YSA'ya verilme sırası literatüre göre ve deneme yanılma yoluyla dizisel veya rastlantısal olarak uygulanmıştır [169]. Ağ çıkış değerlerinden sınıfların elde edilmesi kazanan hepsini alır (WTA) tekniğine göre yapılmıştır [168], [182]. İlgili piksel, en büyük çıkış değerini üreten işlemci elemanın temsil ettiği kategoriye atanmıştır. Literatüre uygun olarak, çok spektrumlu uzaktan algılama görüntüsünün spektral tabanlı sınıflandırma probleminde, optimum ağ yapısının ve eğitim epoğunun belirlenmesinde, test verisi genel sınıflandırma

doğruluğu kriter performans ölçütü olarak göz önüne alınmıştır [21]. Genel sınıflandırma doğruluğunun eğitim ve test verileri için belirlenmesinin yanında her iki veri kümesi içinde karesel ortalama hataları (MSE) ve Kappa istatistik değerleri de hesaplanmıştır [170]. Bu tez çalışmasında Kappa katsayıları YSA sınıflandırma yaklaşımlarının hem kendi aralarında hem de klasik MO yöntemiyle karşılaştırılabilmesi için kullanılmıştır. Bu doğruluk ölçütlerine ek olarak, farklı sınıflandırma yaklaşımlarıyla elde edilen sınıflandırma sonuçları arasındaki uygunluğu belirlemek için bütün sınıflandırma görüntüleri piksel piksel karşılaştırılarak sınıflandırma uygunluk matrisleri hesaplanmıştır. Ayrıca her bir öğrenme algoritması için belirlenen en optimum ağ yapısından elde edilen sınıflandırılmış tüm görüntüyle, MO yönteminden elde edilen sınıflandırma görüntüsü arasında çapraz sınıflandırma matrisleri hesaplanmıştır. Farklı sınıflandırma yaklaşımları arasındaki rölatif farkın bir ölçütü olan çapraz sınıflandırma matrisleri, görüntünün tamamını esas alan sınıflandırma sonuçları arasındaki farkı toplam görüntü piksel sayısı ile orantılı olarak ortaya koyacak şekilde düzenlenmiştir [21]. Bu matrisler için kullanılan GU kısaltması ilgili iki sınıflandırma yaklaşımı arasındaki genel uygunluğu göstermektedir. Genel uygunluk kavramı, her iki sınıflandırma yaklaşımında da aynı sınıfa atanan toplam piksel sayısını tüm görüntünün yüzdesi olarak gösterir.

Eğitim aşamasında oluşturulan bir kod aracılığıyla YSA eğitim sürecinde her 100 epokta bir eğitim ve test verisi için genel sınıflandırma doğruluk değerleri, Kappa katsayıları ve karesel ortalama hata (MSE) değerleri hesaplanmıştır. Bu şekilde literatürde sürekli bir yapıda gerçekleştirilen YSA eğitiminin kesikli bir tarzda yapılmasıyla ağı aşırı eğitilmesinin önüne geçilmiş ve sınıflandırma problemi için en optimum ağ bulunmuştur. Ayrıca uygulanan bu eğitim yöntemiyle BFGS, EGPB, EGFR, EGPR, EG, TAS ve ÖEG algoritmaları için yakınsama doğruluğu ve hızı araştırılmıştır. Ağı eğitim süreci, test verisi sınıflandırma genel doğruluk değeri kesin bir azalma veya sabit kalma eğilimi gösterinceye kadar sürdürülmüştür. Yapılan analizlerde test verisi genel sınıflandırma doğruluk değeri artmaya devam eden veya yeterince azalma kesinliğine ulaşmamış olan ağların eğitime devam edilmiştir. Uygulanan RBF ve LVQ YSA yapılarının eğitilmesi ve optimum ağ yapılarının seçilmesinde de test verisi genel sınıflandırma doğruluk performansı kullanılmıştır. Ağların eğitim süreci yine test verisi sınıflandırma doğruluk değeriyle

kontrol edilmiştir. Aşağıdaki Tablo 6.13’de MLP yapılarının ağ eğitim epok sayıları gösterilmektedir.

Tablo 6.13: MLP yapılarının eğitiminde elde edilen epoklar.

YAPI NO	DELTA	DBD	EDBD	BFGS	EGPB	EGFR	EGPR	TAS	EG	ÖEG
1	5000	10000	7500	10000	10000	10000	10000	30000	10000	10000
2	5000	12500	10000	10000	10000	10000	10000	30000	10000	10000
3	5000	10000	10000	15000	10000	10000	10000	30000	15000	15000
4	5000	10000	10000	15000	10000	15000	10000	35000	15000	15000
5	5000	10000	10000	15000	10000	10000	10000	35000	15000	15000
6	5000	12500	1500	10000	10000	10000	10000	10000	10000	1000
7	5000	10000	5000	15000	15000	15000	15000	15000	15000	15000
8	5000	10000	5000	15000	15000	15000	15000	15000	15000	15000
9	5000	10000	5000	11700	15000	15000	15000	15000	15000	15000

Ayrıca, bu tez çalışması kapsamında uygulanan öğrenme algoritmaları ve yapılarının çok spektrumlu görüntülerin sınıflandırılmasındaki davranışlarını görsel olarak analiz edebilmek amacıyla her biri için iki boyutlu özellik uzayındaki karar bölgeleri oluşturulmuştur. Ağ yapıları, iki boyutlu özellik uzayındaki karar bölgelerinin oluşturulması için ağ topolojileri iki girişli olarak yeniden organize edilmiştir. Kullanılacak iki giriş için literatüre uygun olarak LANDSAT TM 3. ve 4. kanallar seçilmiştir [187]. Bu kanallar, özellikle bitki örtüsünün diğer kategorilerden çok iyi ayrılabilirdiği ve birbiriyle korelasyonu çok düşük olan kanallardır (Tablo 6.14).

Tablo 6.14: LANDSATM kanal korelasyon değerleri.

Kanal	1	2	3	4	5	7
1	1	0.96752	0.95955	0.15262	0.69800	0.86722
2		1	0.98701	0.27077	0.76907	0.90058
3			1	0.20225	0.77568	0.92329
4				1	0.56978	0.28647
5					1	0.9022
7						1

6.7.1. MLP YSA Yapısı Uygulaması


6.7.1.1 Delta Öğrenme Algoritması

Delta öğrenme algoritmasının uygulanmasında kullanılan öğrenme oranı 0.01 ve momentum parametresi de 0.5 olarak ayarlanmıştır. Oluşturulan bütün yapılarda eğitim verisinin YSA’ya giriş sırası rastlantısal olarak düzenlenmiştir. Delta algoritması ile gerçekleştirilen sınıflandırma uygulamaları sonucunda elde edilen GD, Kappa ve MSE değerleri Tablo 6.15’te verilmektedir.

Tablo 6.15: Delta algoritması ile elde edilen GD, Kappa ve MSE değerleri.

YAPI NO	EĞİTİM VERİSİ			TEST VERİSİ			Epok
	GD	Kappa	MSE	GD	Kappa	MSE	
1	94.0	93.4	0.0075	89.5	88.1	0.0135	200
2	94.6	94.0	0.0072	89.3	87.9	0.0138	400
3	94.4	94.0	0.0071	89.9	87.9	0.0132	400
4	94.8	94.2	0.0070	90.0	88.7	0.0130	400
5	94.5	93.9	0.0072	89.7	88.3	0.0137	800
6	93.1	92.2	0.0086	89.0	87.6	0.0141	100
7	95.2	94.6	0.0060	88.5	87.1	0.0154	200
8	95.6	95.1	0.0054	89.4	88.1	0.0141	200
9	96.1	95.7	0.0046	89.4	88.0	0.0141	700

Delta algoritması ile gerçekleştirilen sınıflandırma uygulamaları sonucunda GD ölçütüne göre test verileri için en yüksek performansı sağlayan YSA yapısı 4 nolu yapı olarak belirlenmiştir. Bu yapının eğitim süreci sırasında elde edilen GD-Epok ve MSE-Epok grafikleri Şekil 6.10'de gösterilmektedir. Bu yapı için elde edilen test verisi hata matrisi Tablo 6.16'da ve diğer yapılar için elde edilen üretici doğruluk değerleri Tablo 6.17'de verilmektedir.




Şekil 6.10: Delta kuralıyla 4 nolu MLP yapısında; (a) GD-Epok ve (b) MSE-Epok grafikleri.

Eğitimde, test verisi GD ve MSE performans eğrileri birbiriyle tutarlı gerçekleşmiştir. GD ve MSE ters orantılı olarak, GD artarken MSE azalmış ve azalırken de artmıştır. Bu durum ağın örnek veriyi öğrendiğini göstermektedir. Belirli bir noktadan sonra meydana gelen değişimler o kadar küçük olmuştur ki performanstaki değişimler kullanılan ondalık basamak inceliğinin altında kalmıştır.

Tablo 6.16: Delta 4 nolu yapının test verisi hata matrisi (GD=%90.0, Kappa=%88.7).

	Sınıf	REFERANS VERİ												TP	KD
		1	2	3	4	5	6	7	8	9	10	11	12		
SINIFLANDIRILMIŞ VERİ	1	653	14	0	0	0	0	0	0	0	0	0	0	667	97.9
	2	69	352	1	0	11	0	0	0	0	0	0	0	433	81.3
	3	0	23	240	0	0	0	0	0	0	6	0	0	269	89.2
	4	0	0	0	92	0	0	0	13	0	1	12	0	118	78
	5	0	0	0	0	149	0	0	0	0	0	0	0	149	100
	6	0	0	0	0	0	109	4	0	0	0	3	0	116	94
	7	0	0	0	0	0	12	127	0	5	0	0	0	144	88.2
	8	0	0	0	9	0	2	0	80	6	52	9	0	158	50.6
	9	0	0	1	0	0	9	0	0	297	6	14	0	327	90.8
	10	0	0	0	0	0	0	0	6	2	215	42	0	265	81.1
	11	0	0	0	2	0	2	0	1	13	16	397	0	431	92.1
	12	0	0	0	0	0	0	0	0	0	0	0	571	571	100
TP		722	389	242	103	160	134	131	100	323	296	477	571	3648	
ÜD		90.4	90.5	99.2	89.3	93.1	81.3	96.9	80	92	72.6	83.2	100		

Test verisi hata matrisine göre 8 ve 10 nolu sınıflar en düşük doğruluk değerleri vermişlerdir. Büyük oranda 8 nolu sınıf, 4 nolu sınıfla ve 10 nolu sınıf da 8 nolu sınıfla karışmıştır. Delta algoritmasının iki boyutlu eğitim ve test verileri için %87.4 ve %85.3 GD ile ürettiği karar bölgeleri Şekil 6.11'de verilmektedir. Bu işlem için olan test verisi hata matrisine göre en düşük performans gösteren sınıflar 6 ve 8 nolu sınıflardır. Bu sınıflar 11 ve 4 nolu sınıflarla karışım göstermişlerdir. Özellik uzayında 4, 6, 8 ve 11 nolu sınıflar en fazla temsil edilen sınıflardır. Bu sınıflardan 8 nolu sınıfın kullanıcı doğruluk değeri en düşüktür. Delta karar bölgelerinde 8 ve 10 nolu sınıf dağılımlarının oldukça küçüldüğü, 11 ve 6 nolu sınıf dağılımlarının ise arttığı görülmektedir.



Şekil 6.11: Delta öğrenme kuralının oluşturduğu karar bölgeleri.

Tablo 6.17: Delta yapılarının test verisi üretici doğruluk değerleri.

SINIF	MLP Yapı No								
	1	2	3	4	5	6	7	8	9
1	90.9	90.7	90.7	90.4	90.7	90.7	90.9	91.3	91.7
2	88.2	87.7	89.7	90.5	90.2	93.6	91.8	90.0	91.0
3	97.5	97.9	98.8	99.2	98.3	86.0	93.8	98.3	95.0
4	92.2	90.3	91.3	89.3	88.4	91.3	94.2	94.2	95.1
5	93.1	92.5	93.1	93.1	92.5	96.3	93.1	92.5	93.1
6	79.9	79.1	76.9	81.3	76.9	88.1	77.6	77.6	76.9
7	94.7	96.2	95.4	96.9	95.4	90.8	96.2	95.4	94.7
8	76.0	79.0	81.0	80.0	81.0	63.0	72.0	72.0	80.0
9	93.5	93.2	92.6	92.0	93.5	90.7	91.3	92.0	90.7
10	73.0	75.3	72.6	72.6	70.6	67.2	66.6	76.0	75.3
11	81.8	79.2	83.4	83.2	83.2	85.7	79.5	78.8	78.4
12	100	100	100	100	100	100	100	100	100

Tablo 6.18’de Delta 4 nolu yapının MO yöntemiyle olan çapraz sınıflandırma matrisi verilmiştir. MO yöntemiyle en büyük uygunluk değerini 5 ve 12 nolu sınıflar vermiştir. Tablo 6.19’da ise diğer YSA yapılarının kendi aralarında ve MO yöntemiyle olan genel uygunluk matrisi verilmiştir. Delta yapılarının genel uygunluk verilerine göre 4 nolu ağ yapısı MO yöntemiyle en büyük uygunluğa sahiptir.

Tablo 6.18: Delta 4 nolu yapı ve MO çapraz sınıflandırma matrisi (GU=%68).

	Sınıf	MAKSİMUM OLABİLİRLİK											
		1	2	3	4	5	6	7	8	9	10	11	12
DELTA	1	0.136	0.013	0.003	0	0	0	0	0.003	0	0	0	0
	2	0.005	0.114	0.019	0	0	0	0.001	0.023	0	0	0	0
	3	0.001	0.047	0.108	0	0	0	0	0.094	0	0.005	0	0
	4	0	0	0	0.006	0	0	0	0.001	0	0	0	0
	5	0	0.001	0	0	0.001	0	0.002	0.001	0	0	0	0
	6	0	0	0	0	0	0.006	0.001	0.001	0	0	0	0
	7	0	0	0	0	0	0.001	0.016	0.007	0.001	0	0	0
	8	0	0	0	0.006	0	0	0	0.13	0.003	0.006	0.001	0
	9	0	0	0	0.001	0	0	0.001	0.01	0.068	0.005	0.004	0
	10	0	0	0.001	0.004	0	0	0	0.026	0.001	0.053	0.002	0
	11	0	0	0	0.001	0	0	0	0.002	0.003	0.003	0.021	0
	12	0.001	0	0	0	0	0.002	0	0.004	0	0	0	0.021

Tablo 6.19: Delta yapılarının kendi içinde ve MO yöntemiyle olan uygunluk matrisi.

	MO	1	2	3	4	5	6	7	8	9
MO	100	66.6	67.8	67.2	68.0	67.6	62.7	64.8	64.0	65.4
1		100	89.5	91.7	92.4	91.9	82.8	88.9	86.4	88.2
2			100	92.9	93.7	92.7	80.9	85.2	84.7	86.5
3				100	95.3	94.9	83.4	88.7	86.6	89.0
4					100	95.2	82.2	87.7	86.3	88.0
5						100	83.4	88.3	86.4	88.6
6							100	87.9	84.6	85.3
7								100	90.2	91.3
8									100	90.6
9										100


6.7.1.2 Delta-Bar-Delta Öğrenme Algoritması

Bütün ağ topolojileri için eğitim verisinin YSA'ya giriş sırası dizesel sırayla gerçekleştirilmiştir. Gerçekleştirilen mevcut sınıflandırma problemi için bu öğrenme tekniğinin rastlantısal giriş sırasıyla kesinlikle iyi sonuçlar vermediği gözlenmiştir. Bu öğrenme algoritmasıyla gerçekleştirilen sınıflandırma uygulamaları sonucunda elde edilen GD, Kappa ve MSE değerleri Tablo 6.20'de verilmektedir.

Tablo 6.20: DBD algoritması ile elde edilen GD, Kappa ve MSE değerleri.

YAPI NO	EĞİTİM VERİSİ			TEST VERİSİ			Epok
	GD	Kappa	MSE	GD	Kappa	MSE	
1	96.4	96.0	0.0049	91.1	90.0	0.0126	7200
2	96.3	95.9	0.0045	90.0	88.8	0.0137	9400
3	95.2	94.6	0.0063	90.5	89.2	0.0129	1700
4	94.3	93.6	0.0072	90.7	89.5	0.0122	1400
5	95.4	94.8	0.0060	90.9	89.7	0.0121	2900
6	95.2	94.6	0.0061	89.3	87.9	0.0147	10000
7	95.5	95.0	0.0055	89.1	87.7	0.0148	8100
8	95.8	95.3	0.0052	89.8	88.5	0.0139	6100
9	95.7	95.2	0.0053	88.9	87.5	0.0148	4500

DBD algoritması ile gerçekleştirilen sınıflandırma uygulamaları sonucunda GD ölçütüne göre test verisi için en yüksek performansı sağlayan yapı 1 nolu yapı olarak belirlenmiştir. Bu yapının eğitim süreci sırasında elde edilen GD-Epok ve MSE-Epok grafikleri Şekil 6.12’de gösterilmektedir. Bu yapı için elde edilen test verisi hata matrisi Tablo 6.21’de ve diğer yapılar için elde edilen test verisi üretici doğruluk değerleri Tablo 6.22’de verilmektedir.




Şekil 6.12: DBD kuralıyla 1 nolu MLP yapısında; (a) GD-Epok ve (b) MSE-Epok grafiği.

Yukarıdaki performans yüzeylerine göre DBD öğrenme algoritması eğitim sürecinde hem karesel ortalama hata (MSE) hem de sınıflandırma doğruluğu için oldukça büyük salınımlar yapmıştır. Performans yüzeyindeki bu sıçramalar her bir bağlantı ağırlık değeri için sürekli güncellenen farklı öğrenme oranı değerlerinin kullanılmasından kaynaklanmaktadır. Çünkü uygulamada herhangi bir ağırlık değeri için uygun olan öğrenme oranı diğer ağırlık değerleri için uygun olmayabilir. Bu salınımların dikkat çekici diğer bir özelliği de ağırlık optimal performans noktasına doğru (global minimum) yaklaştıkça genliklerinin artmasıdır. Ayrıca Eğitimde, test verisi GD ve MSE performans eğrileri birbiriyle tutarlı gerçekleşmiştir. GD ve MSE ters orantılı olarak GD artarken MSE azalmış ve azalırken de artmıştır.

Tablo 6.21: DBD 1 nolu yapının test verisi hata matrisi (GD=%91.1, Kappa=%90.0).

		REFERANS VERİ													
	Sınıf	1	2	3	4	5	6	7	8	9	10	11	12	TP	KD
SINIFLANDIRILMIŞ VERİ	1	662	5	0	0	0	0	0	0	0	0	0	0	667	99.3
	2	60	360	16	0	9	0	0	0	0	0	0	0	445	80.9
	3	0	24	226	0	0	0	0	0	0	3	0	0	253	89.3
	4	0	0	0	77	0	0	0	7	0	4	8	0	96	80.2
	5	0	0	0	0	151	0	0	0	0	0	0	0	151	100
	6	0	0	0	0	0	115	4	0	0	0	2	0	121	95
	7	0	0	0	0	0	8	125	0	4	0	0	0	137	91.2
	8	0	0	0	25	0	3	0	84	4	32	24	0	172	48.8
	9	0	0	0	0	0	7	2	0	304	5	13	0	331	91.8
	10	0	0	0	0	0	0	0	8	1	241	22	0	272	88.6
	11	0	0	0	1	0	1	0	1	10	11	408	0	432	94.4
	12	0	0	0	0	0	0	0	0	0	0	0	571	571	100
TP	722	389	242	103	160	134	131	100	323	296	477	571	3648		
ÜD	91.7	92.5	93.4	74.8	94.4	85.8	95.4	84	94.1	81.4	85.5	100			

Test verisi hata matrisine göre en düşük performansı 4 ve 10 nolu sınıflar vermiştir. 4 nolu sınıf 8 nolu sınıfla ve 10 nolu sınıf 8 nolu sınıfla önemli ölçüde karışım göstermiştir. DBD öğrenme algoritmasının iki boyutlu eğitim ve test verisi için %87.9 ve %84.8 GD ile ürettiği karar bölgeleri Şekil 6.13’da gösterilmektedir. Bu işlem için elde edilen hata matrisine göre 8 nolu sınıf en düşük doğruluklu sınıf olarak ortaya çıkmıştır. Bu sınıf 4 ve 10 nolu sınıflarla karışmıştır.



Şekil 6.13: DBD öğrenme kuralının oluşturduğu karar uzayları.

Tablo 6.22: DBD yapılarının test verisi üretici doğruluk değerleri.

SINIF	MLP Yapı No								
	1	2	3	4	5	6	7	8	9
1	91.7	91.6	91.3	91.0	90.6	92.4	90.9	91.7	93.4
2	92.5	91.3	90.7	92.0	91.8	89.5	90.5	92.0	7.7
3	93.4	95.0	97.1	98.3	92.6	97.9	98.3	90.5	99.6
4	74.8	92.2	91.3	92.2	91.3	93.2	92.2	95.1	80.6
5	94.4	92.5	93.1	93.8	92.5	92.5	93.8	92.5	90
6	85.8	79.1	79.1	81.3	82.8	64.9	73.1	76.9	79.1
7	95.4	94.7	96.2	94.7	93.1	91.6	90.1	94.7	34.4
8	84.0	80.0	85.0	73.0	84.0	72.0	85.0	79.0	86.0
9	94.1	92.9	92.6	93.5	94.7	87.0	88.9	92.9	73.4
10	81.4	79.7	75.7	76.4	81.4	76.0	72.3	76.7	48.6
11	85.5	79.5	83.6	84.9	84.7	85.1	80.7	81.1	80.9
12	100	100	100	100	100	100	100	100	100

Tablo 6.23’de DBD 1 nolu yapısının MO yöntemi ile olan çapraz sınıflandırma matrisi verilmektedir. MO yöntemiyle en büyük uygunluk değerini 5 ve 12 nolu sınıflar elde etmiştir. Tablo 6.24’de ise DBD yapılarının hem kendi aralarında hem de MO yöntemiyle olan genel uygunluk matrisleri verilmektedir. MO yöntemiyle olan en büyük genel uygunluk değerini 2 nolu yapı vermiştir.

Tablo 6.23: DBD 1 nolu yapı ve MO çapraz sınıflandırma matrisi (GU=%68.7).

Sınıf	MAKSİMUM OLASILIK											
	1	2	3	4	5	6	7	8	9	10	11	12
1	0.139	0.008	0.003	0	0	0	0	0.003	0	0	0	0
2	0.004	0.12	0.021	0.001	0	0	0.001	0.034	0	0.001	0	0
3	0.001	0.045	0.105	0	0	0	0	0.08	0	0.004	0	0
4	0	0	0	0.006	0	0	0	0.001	0	0	0	0
5	0	0.001	0	0	0.001	0.001	0.003	0.002	0	0	0	0
6	0	0	0	0	0	0.006	0.001	0.001	0	0	0.001	0
7	0	0	0	0	0	0.001	0.015	0.004	0.001	0	0	0
8	0	0	0	0.009	0	0	0.001	0.132	0.003	0.01	0.001	0
9	0	0	0	0.001	0	0	0.001	0.007	0.07	0.004	0.004	0
10	0	0	0.002	0.002	0	0	0	0.032	0.001	0.052	0.001	0
11	0	0	0	0.001	0	0	0	0.001	0.003	0.002	0.021	0
12	0	0	0	0	0	0.002	0	0.003	0	0	0	0.021

Tablo 6.24: DBD yapılarının kendi içinde ve MO yöntemiyle olan uygunluk matrisi.

MO	1	2	3	4	5	6	7	8	9
MO	100	68.7	68.9	67.2	65.5	67.3	68.1	62.7	53.4
1		100	86.0	88.5	87.2	86	81.5	80.1	66.9
2			100	87.4	82.5	85.9	77.7	78.9	64.1
3				100	89.9	87.8	80.2	80.3	69.4
4					100	88.1	79.9	79.3	69.3
5						100	80.0	79.6	65.4
6							100	76.0	63.6
7								100	63.3
8									100
9									


6.7.1.3 Genişletilmiş Delta-Bar-Delta Öğrenme Algoritması

Genişletilmiş Delta-Bar-Delta algoritması ile gerçekleştirilen sınıflandırma uygulamalarında eğitim giriş verisinin YSA'ya giriş sırası tek katmanlı yapılar için rastlantısal olarak ayarlanırken iki katmanlı ağlar için sıralı bir şekilde ayarlanmıştır. Bu algoritmanın uygulanması sonucunda elde edilen GD, Kappa ve MSE değerleri Tablo 6.25'de verilmektedir.

Tablo 6.25: EDBD algoritması ile elde edilen GD, Kappa ve MSE değerleri

YAPI NO	EĞİTİM VERİSİ			TEST VERİSİ			Epok
	GD	Kappa	MSE	GD	Kappa	MSE	
1	95.0	94.5	0.0066	89.0	87.6	0.0141	700
2	94.8	94.2	0.0071	89.5	88.1	0.0136	400
3	96.1	95.6	0.0051	90.3	89.1	0.0131	1800
4	95.2	95.2	0.0063	89.9	89.1	0.0131	800
5	95.1	94.5	0.0061	89.7	88.4	0.0132	500
6	91.8	90.9	0.0103	85.0	83.2	0.0199	600
7	90.3	89.2	0.0117	86.4	84.7	0.0171	400
8	96.8	96.4	0.0041	89.4	88.1	0.0147	2400
9	93.8	93.1	0.0077	89.6	88.3	0.0139	600

EDBD algoritması ile gerçekleştirilen sınıflandırma uygulamaları sonucunda GD ölçütüne göre test verisi için en yüksek performansı sağlayan yapı 3 nolu yapı olarak belirlenmiştir. Bu yapının eğitim süreci sırasında elde edilen GD-Epok ve MSE-Epok grafikleri Şekil 6.14'de gösterilmektedir. Bu yapı için elde edilen test verisi hata matrisi Tablo 6.26'da ve diğer yapılar için elde edilen test verisi üretici doğruluk değerleri de Tablo 6.27 verilmektedir.



Şekil 6.14: EDBD kuralıyla 3 nolu MLP yapısında; (a) GD-Epok ve (b) MSE-Epok grafiği.


DBD algoritmasında olduğu gibi burada da performans yüzeylerinde büyük sıçramalar görülmektedir. EDBD algoritması da her bir bağlantı ağırlık değeri için

sürekli güncellenen bir öğrenme oranı değeri içerir. Buna ek olarak momentum parametresi de öğrenme oranında olduğu gibi her bir ağırlık değeri için farklı alınır. Bu değerlerin ağıdaki her bir ağırlık değeriyle uyuşmaması yüzünden performans yüzeyinde sıçramalar oluşabilir. EDBD algoritmasında oluşan sıçramaların genliği DBD'ye göre daha küçüktür ve ilerleyen epoğa göre de küçülen bir eğime sahiptir. ayrıca eğitimde, test verisi GD ve MSE performans eğrileri birbiriyle tutarlı gerçekleşmiştir. GD ve MSE ters orantılıdır: GD artarken MSE azalmakta ve azalırken de artmaktadır.

Tablo 6.26: EDBD 3 nolu yapının test verisi hata matrisi (GD=%90.3, Kappa=%89.1).

		REFERANS VERİ													
SINIFLANDIRILMIŞ VERİ	Sınıf	1	2	3	4	5	6	7	8	9	10	11	12	TP	KD
	1	666	4	0	0	0	0	0	0	0	0	0	0	670	99.4
	2	56	361	21	0	10	0	0	0	0	0	0	0	448	80.6
	3	0	24	221	0	0	0	0	0	0	4	0	0	249	88.8
	4	0	0	0	95	0	0	0	5	0	4	19	0	123	77.2
	5	0	0	0	0	150	0	0	0	0	0	0	0	150	100
	6	0	0	0	0	0	109	4	0	0	0	5	0	118	92.4
	7	0	0	0	0	0	13	124	0	6	0	1	0	144	86.1
	8	0	0	0	8	0	5	1	86	5	40	16	0	161	53.4
	9	0	0	0	0	0	6	2	0	300	8	15	0	331	90.6
	10	0	0	0	0	0	0	0	8	1	226	35	0	270	83.7
	11	0	0	0	0	0	1	0	1	11	14	386	0	413	93.5
	12	0	0	0	0	0	0	0	0	0	0	0	571	571	100
TP		722	389	242	103	160	134	131	100	323	296	477	571	3648	
ÜD		92.2	92.8	91.3	92.2	93.7	81.3	94.7	86	92.9	76.4	80.9	100		

Test verisi hata matrisine göre en düşük performansı 8 nolu sınıfla karışan 10 nolu sınıf vermiştir. EDBD yapısının eğitim ve test verileri için %87.1 ve %85.0 GD ile ürettiği karar bölgeleri Şekil 6.15'de verilmiştir. Sınıfların dağılımları Delta algoritmasına benzemesine rağmen özellikle 8 ve 11 nolu sınıfların alanları daralmıştır. 1 nolu sınıf y-ekseninde biraz daha ilerlemiş ve 12 nolu sınıf bu boşluğu doldurarak genişlemiştir. Buna bağlı olarak 2 nolu sınıfın alanı da daralmıştır. Bu işlemin hata matrisine göre en düşük performans değeri 8 nolu sınıftan elde edilmiştir.



Şekil 6.15: EDBD öğrenme kuralının oluşturduğu karar bölgeleri.

Tablo 6.27: EDBD yapılarının test verisi sınıflandırma üretici doğruluk değerleri.

SINIF	MLP Yapı No								
	1	2	3	4	5	6	7	8	9
1	91.8	91.6	92.2	90.4	91.0	87.3	86.8	91.6	89.6
2	89.2	90.2	92.8	92.3	89.2	88.4	93.8	85.9	92.8
3	95.0	95.0	91.3	95.0	95.0	92.6	99.2	97.5	100
4	95.1	90.3	92.2	88.4	89.3	88.4	95.1	92.2	87.4
5	94.4	92.5	93.8	93.1	92.5	95.0	92.5	95.6	96.3
6	79.1	76.9	81.3	79.9	77.6	88.1	72.4	73.9	81.3
7	94.7	96.2	94.7	93.9	96.9	93.1	93.9	94.7	95.4
8	83.0	77.0	86.0	82.0	84.0	63.0	59.0	78.0	76.0
9	88.2	92.3	92.9	92.3	91.6	87.9	93.2	94.4	93.2
10	72.6	74.0	76.4	78.7	75.0	53.7	56.8	79.1	73.6
11	78.4	81.3	80.9	83.9	82.6	72.1	74.6	78.2	78.8
12	100	100	100	100	100	100	100	100	100

Tablo 6.28’de MO ve EDBD 3 nolu yapısı arasındaki çapraz sınıflandırma matrisi verilmiştir. Elde edilen en büyük uygunluk değerleri 5 ve 12 nolu sınıflar için gerçekleşmiştir. Tablo 6.29’da YSA yapılarının kendi aralarında ve MO ile olan genel uygunluk değerleri verilmiştir. MO ile en büyük genel uygunluk değerini 3 nolu yapı vermiştir.

Tablo 6.28: EDBD 3 nolu yapı ve MO çapraz sınıflandırma matrisi (GU=%67.7).

MAKSİMUM OLABİLİRLİK												
Sınıf	1	2	3	4	5	6	7	8	9	10	11	12
1	0.137	0.007	0.002	0	0	0	0	0.003	0	0	0	0
2	0.005	0.126	0.023	0.001	0	0	0.001	0.029	0	0.001	0	0
3	0.001	0.039	0.106	0	0	0	0	0.091	0	0.002	0	0
4	0	0	0	0.006	0	0	0	0.001	0	0	0	0
5	0	0.001	0	0	0.001	0.001	0.002	0.002	0	0	0	0
6	0	0	0	0	0	0.006	0	0.001	0	0	0.001	0
7	0	0	0	0	0	0.001	0.016	0.007	0.001	0	0	0
8	0	0	0	0.008	0	0	0.001	0.114	0.002	0.008	0.001	0
9	0	0	0	0	0	0	0.001	0.006	0.069	0.004	0.004	0
10	0	0.001	0.001	0.002	0	0	0	0.042	0	0.055	0.001	0
11	0	0	0	0.001	0	0	0	0.002	0.004	0.003	0.019	0
12	0.001	0	0	0	0	0.002	0	0.004	0	0	0	0.021

Tablo 6.29: EDBD yapılarının kendi içinde ve MO yöntemiyle olan uygunluk matrisi.

MO	1	2	3	4	5	6	7	8	9
MO	100	64.1	66.3	67.7	70.2	66.4	63.9	68.2	65.7
1		100	89.7	85.7	86.3	91.3	80.5	78.5	84
2			100	86	88.3	92.1	79.9	81.4	83.3
3				100	87.8	88.8	76.5	77.2	82.6
4					100	90.4	76.7	80	83.7
5						100	79.2	80	85.1
6							100	83.5	75
7								100	76.3
8									100
9									

6.7.1.4 BFGS Kuasi-Newton Öğrenme Algoritması


BFGS algoritması ile gerçekleştirilen sınıflandırma uygulamalarında eğitim giriş vektörlerinin ağı verilmesi sıralı olarak gerçekleştirilmiştir. Bu algoritmayla elde edilen GD, Kappa ve MSE değerleri Tablo 6.30'da verilmektedir.

Tablo 6.30: BFGS algoritması ile elde edilen GD, Kappa ve MSE değerleri

YAPI NO	EĞİTİM VERİSİ			TEST VERİSİ			Epok
	GD	Kappa	MSE	GD	Kappa	MSE	
1	91.9	91.0	0.0133	83.5	81.4	0.0191	4300
2	92.9	92.1	0.0146	87.7	86.1	0.0230	5600
3	93.5	92.7	0.0130	88.0	86.4	0.0217	9900
4	92.6	91.7	0.0168	88.8	87.3	0.0239	1400
5	93.8	93.1	0.0120	88.8	87.3	0.0210	4100
6	94.7	94.3	0.0081	85.9	84.1	0.0204	6700
7	92.4	93.1	0.0133	89.5	88.3	0.0191	600
8	93.8	93.1	0.0111	89.6	88.3	0.0175	600
9	96.1	95.6	0.0068	90.5	89.3	0.0154	2000

BFGS algoritması ile gerçekleştirilen sınıflandırma uygulamaları sonucunda GD ölçütüne göre test verisi için en yüksek performansı sağlayan yapı 9 nolu yapı olarak

belirlenmiştir. Bu yapının eğitim süreci sırasında elde edilen GD-Epok ve MSE-Epok grafikleri Şekil 6.16'de gösterilmektedir. Bu yapı için elde edilen test verisi hata matrisi Tablo 6.31'de ve diğer yapılar için elde edilen test verisi üretici doğruluk değerleri ise Tablo 6.32'de verilmektedir.



Şekil 6.16: BFGS kuralıyla 9 nolu MLP yapısında; (a) GD-Epok ve (b) MSE-Epok grafiği.


Eğitimde, test verisi GD ve MSE performans eğrileri birbiriyle tutarlı gerçekleşmiştir. GD ve MSE ters orantılı olarak GD artarken MSE azalmış ve azalırken de artmıştır. Bu durumda ağın iyi bir genelleme derecesine sahip olacağı beklenmiştir.

Tablo 6.31: BFGS 9 nolu yapının test verisi hata matrisi (GD=%90.5, Kappa=%89.3).

		REFERANS VERİ													
SINIFLANDIRILMIŞ VERİ	Sınıf	1	2	3	4	5	6	7	8	9	10	11	12	TP	KD
	1	658	17	0	0	0	0	0	0	0	0	0	0	675	97.5
	2	64	348	1	0	13	0	0	0	0	0	0	0	426	81.7
	3	0	24	240	0	0	0	0	0	0	7	0	0	271	88.6
	4	0	0	0	92	0	0	0	12	0	0	6	0	110	83.6
	5	0	0	0	0	147	0	0	0	0	0	0	0	147	100
	6	0	0	0	0	0	97	4	0	1	0	0	0	102	95.1
	7	0	0	0	0	0	13	123	0	1	0	1	0	138	89.1
	8	0	0	1	5	0	9	1	78	2	38	8	0	142	54.9
	9	0	0	0	0	0	14	3	0	309	7	12	0	345	89.6
	10	0	0	0	5	0	0	0	9	1	232	43	0	290	80
	11	0	0	0	1	0	1	0	1	9	12	407	0	431	94.4
	12	0	0	0	0	0	0	0	0	0	0	0	571	571	100
TP		722	389	242	103	160	134	131	100	323	296	477	571	3648	
ÜD		91.1	89.5	99.2	89.3	91.9	72.4	93.9	78	95.7	78.4	85.3	100		

Test verisi hata matrisine göre 6, 8 ve 10 nolu sınıfların sahip olduğu doğruluk değerleri en düşük seviyede gerçekleşmiştir. 6 nolu sınıf 7, 8 ve 9 nolu sınıflarla, 8 nolu sınıf 4 nolu sınıfla ve 10 nolu sınıfta 8 nolu sınıfla önemli ölçüde karışmıştır. BFGS yapısının eğitim ve test verileri için %85.7 ve %81.2 GD ile ürettiği karar

bölgeleri Şekil 6.17’de gösterilmektedir. MO ile karşılaştırıldığında en dikkat çekici özelliğin 8 nolu sınıfın önemli ölçüde küçülmesi, 12 nolu sınıfın iki ayrı bölgede oluşması ve 6 nolu sınıfın büyümesi olmuştur. 12 nolu sınıfın sahip olduğu ikinci bölge x eksenine (3. Kanal) doğru yüksek parlaklık seviyelerinde oluşmuştur. 2, 3, ve 4 nolu sınıflarda daha geniş alanlara dağılmışlardır. Özellikle 11 nolu sınıf yaklaşık köşegen boyunca pozitif yüksek bir korelasyonla sürekli bir koridor oluşturmuştur. Bu işlem hata matrisine göre 8 nolu sınıf en düşük doğruluk değerini vermiştir. Bu sınıf 4, 10 ve 11 nolu sınıflarla karışmıştır.



Şekil 6.17: BFGS öğrenme kuralının ürettiği karar bölgeleri.

Tablo 6.32: BFGS yapılarının test verisi üretici doğruluk değerleri.

SINIF	MLP Yapı No								
	1	2	3	4	5	6	7	8	9
1	88.5	88.9	89.5	89.3	90.2	90.4	92.7	90.0	91.1
2	59.4	85.9	86.9	85.3	87.1	71.2	79.9	85.6	89.5
3	69.0	85.5	91.3	87.6	95.0	87.2	94.2	99.6	99.2
4	81.6	87.4	82.5	90.3	87.4	81.6	95.1	92.2	89.3
5	90.6	93.8	92.5	93.8	91.3	91.9	93.1	91.9	91.9
6	70.1	72.4	73.1	79.1	76.1	85.8	75.4	75.4	72.4
7	95.4	93.9	87.8	97.7	94.7	88.5	94.7	96.9	93.9
8	57.0	68.0	69.0	62.0	71.0	80.0	72.0	69.0	78.0
9	95.0	92.0	92.3	95.7	93.8	94.4	93.8	95.0	95.7
10	72.0	79.1	77.4	71.3	75.3	68.9	77.0	76.7	78.4
11	86.6	80.7	82.2	88.3	81.6	77.4	86.0	84.3	85.3
12	100	100	100	100	100	100	100	100	100

BFGS 9 nolu yapının MO ile olan çapraz sınıflandırma matrisi Tablo 6.34’de verilmektedir. MO yönteminin BFGS 9 nolu yapı ile olan en büyük uygunluk değeri 5 ve 12 nolu sınıflar için elde edilmiştir. Tablo 6.35’te BFGS yapılarının kendi aralarında ve MO yöntemiyle olan genel uygunluk değerleri verilmiştir. En büyük uygunluk değerini 9 nolu yapı vermiştir.

Tablo 6.33: BFGS 9 nolu yapı ve MO çapraz sınıflandırma matrisi (GU=%67.4).

		MAKSİMUM OLABİLİRLİK											
BFGS	Sınıf	1	2	3	4	5	6	7	8	9	10	11	12
	1	0.138	0.017	0.003	0	0	0	0	0.002	0	0	0	0
	2	0.004	0.117	0.017	0.001	0	0	0.003	0.018	0	0.001	0	0
	3	0	0.04	0.11	0	0	0	0	0.114	0	0.005	0	0
	4	0	0	0	0.006	0	0	0	0.001	0	0	0	0
	5	0.001	0.001	0	0	0.001	0	0.001	0.001	0	0	0	0
	6	0	0	0	0	0	0.005	0	0	0	0	0	0
	7	0	0	0	0	0	0.001	0.015	0.014	0	0	0	0
	8	0	0	0.001	0.007	0	0.001	0.001	0.114	0.002	0.007	0	0
	9	0	0	0	0.001	0	0.001	0.001	0.012	0.071	0.005	0.003	0
	10	0	0	0	0.003	0	0	0	0.019	0.001	0.054	0.001	0
	11	0	0	0	0.001	0	0	0	0.002	0.003	0.002	0.022	0
	12	0.001	0	0	0	0	0.002	0	0.003	0	0	0	0.021

Tablo 6.34: BFGS yapılarının kendi içinde ve MO yöntemiyle olan uygunluk matrisi.

	MO	1	2	3	4	5	6	7	8	9
MO	100	60.8	64.6	62.8	61.8	63.9	65.5	62.9	66.2	67.4
1		100	86.1	82.1	80	78.2	76.7	79.9	79.9	77.1
2			100	86.1	80.8	79.5	76.1	82.7	81.8	79.5
3				100	84.1	83.7	76.8	85.5	83	81.6
4					100	85.7	74.6	82.9	86.5	81.6
5						100	72.7	84.1	86.1	87.1
6							100	75.1	77	75.4
7								100	85.8	82.4
8									100	86.8
9										100


6.7.1.5 Eşleştirmeli Gradyent Powell-Beale Algoritması

EGPB algoritması ile gerçekleştirilen sınıflandırma uygulamalarında eğitim giriş vektörlerinin ağa verilmesi sıralı olarak gerçekleştirilmiştir. Bu algoritmayla elde edilen GD, Kappa ve MSE değerleri Tablo 6.35’de verilmektedir.

Tablo 6.35: EGPB algoritması ile elde edilen GD, Kappa ve MSE değerleri.

YAPI NO	EĞİTİM VERİSİ			TEST VERİSİ			Epok
	GD	Kappa	MSE	GD	Kappa	MSE	
1	88.2	86.8	0.0193	87.7	86.0	0.0237	5400
2	92.3	91.4	0.0156	88.7	87.2	0.0219	2500
3	92.1	91.2	0.0165	88.7	87.2	0.0232	2500
4	93.5	92.7	0.0138	89.4	88.0	0.0232	5700
5	94.0	93.4	0.0120	89.2	87.8	0.0193	7600
6	94.6	94.0	0.0088	90.8	89.6	0.0142	3600
7	96.2	95.8	0.0060	90.0	88.7	0.0152	7300
8	96.4	96.0	0.0064	90.0	88.7	0.0154	4500
9	97.7	97.4	0.0038	90.0	88.7	0.0157	11900

EGPB algoritması ile gerçekleştirilen sınıflandırma uygulamaları sonucunda GD ölçütüne göre test verisi için en yüksek performansı sağlayan yapı 6 nolu yapı olarak belirlenmiştir. Bu yapının eğitim süreci sırasında elde edilen GD-Epok ve MSE-Epok grafikleri Şekil 6.18’de gösterilmektedir. Bu yapı için elde edilen test verisi hata matrisi Tablo 6.36’da ve diğer yapılar için test verisi üretici doğruluk değerleri Tablo 6.37’de verilmektedir.




Şekil 6.18: EGPB kuralıyla 6 nolu MLP yapısında; (a) GD-Epok ve (b) MSE-Epok grafiği.

Eğitimde, test verisi GD ve MSE performans eğrileri birbiriyle tutarlı gerçekleşmiştir.

Tablo 6.36: EGPB 6 nolu yapının test verisi hata matrisi (GD=%90.8, Kappa=%89.6).

	Sınıf	REFERANS VERİ												TP	KD
		1	2	3	4	5	6	7	8	9	10	11	12		
SINIFLANDIRILMIŞ VERİ	1	674	11	0	0	0	0	0	0	0	0	0	0	685	98.4
	2	48	355	2	0	18	0	0	0	0	0	0	0	423	83.9
	3	0	23	240	0	0	0	0	0	0	9	0	0	272	88.2
	4	0	0	0	92	0	0	0	18	0	0	6	0	116	79.3
	5	0	0	0	0	142	0	0	0	0	0	0	0	142	100
	6	0	0	0	0	0	101	3	0	0	0	0	0	104	97.1
	7	0	0	0	0	0	18	121	0	2	0	0	0	141	85.8
	8	0	0	0	7	0	2	0	71	1	34	11	0	126	56.3
	9	0	0	0	0	0	11	7	0	306	6	10	0	340	90
	10	0	0	0	2	0	1	0	11	2	237	49	0	302	78.5
	11	0	0	0	2	0	1	0	0	12	10	401	0	426	94.1
	12	0	0	0	0	0	0	0	0	0	0	0	571	571	100
TP		722	389	242	103	160	134	131	100	323	296	477	571	3648	
ÜD		93.4	91.3	99.2	89.3	88.7	75.4	92.4	71	94.7	80.1	84.1	100		

Test verisi hata matrisine göre en düşük performanslar 6, 8 ve 10 nolu sınıflar için elde edilmiştir. 6 nolu sınıf 7 ve 9 nolu sınıflarla, 8 nolu sınıf 4 ve 10 nolu sınıflarla ve 10 nolu sınıfta 8 nolu sınıfla karışmıştır. EGPB yapısının eğitim ve test verileri için %80.8 ve %80.3 GD ile ürettiği karar bölgeleri Şekil 6.19'da verilmektedir. MO'ya göre 2, 4 ve 11 nolu sınıflar daha geniş ve 8 ve 10 nolu sınıflar da daha dar bir alana yayılmıştır. 3 nolu sınıf konum değiştirerek x ekseninde daha yüksek parlaklık seviyelerine doğru ilerlemiştir. Bütün kanalların sınıflandırılmasın da 6 nolu sınıf için oluşan performans düşüklüğü aynı şekilde iki boyutlu özellik uzayında da gerçekleşmiştir. 6 nolu sınıf bütünüyle 7 ve 9 nolu sınıflara atanmıştır. Bu durum 6 nolu sınıfa ait veriler sınıflandırılmış özellik uzayı üzerine çizdirilerek grafik olarak da analiz edilmiştir. Buna göre 6 nolu sınıfa ait veriler bütünüyle 7 ve 9 nolu sınıflara ait bölgelerde oluşmuştur.



Şekil 6.19: EGPB öğrenme kuralının ürettiği karar bölgeleri.

Tablo 6.37: EGPB yapılarının test verisi üretici doğruluk değerleri.

SINIF	MLP Yapı No								
	1	2	3	4	5	6	7	8	9
1	91.0	89.8	89.3	92.0	90.3	93.4	95.0	93.5	93.2
2	81.5	87.7	88.9	88.4	87.1	91.3	89.5	90.5	90.0
3	98.8	95.5	86.0	99.2	97.1	99.2	92.6	97.1	97.9
4	83.5	86.4	90.3	90.3	87.4	89.3	95.1	90.3	86.4
5	95.6	87.5	96.3	93.8	92.5	88.8	90.0	90.6	90.6
6	71.6	73.9	76.9	73.9	73.1	75.4	78.4	76.1	70.1
7	89.3	96.2	99.2	96.2	96.2	92.4	90.1	96.9	95.4
8	0.0	63.0	70.0	68.0	72.0	71.0	75.0	70.0	86.0
9	93.5	94.7	93.5	94.4	93.8	94.7	94.1	93.8	93.2
10	83.4	70.6	67.2	73.6	75.3	80.1	79.1	77.0	79.7
11	86.6	86.4	86.8	80.5	83.2	84.1	79.0	79.9	78.8
12	100	100	100	100	100	100	100	100	100

EGPB 6 nolu yapının MO yöntemi ile olan çapraz sınıflandırma matrisi Tablo 6.38’de verilmektedir. MO yöntemi ile en büyük uygunluk değerini 5 ve 12 nolu sınıflar vermiştir. Tablo 6.39’da EGPB yapılarının kendi aralarında ve MO yöntemi ile olan genel uygunluk matrisleri verilmektedir. MO ile en büyük genel uygunluk değerini 6 nolu yapı vermiştir.

Tablo 6.38: EGPB 6 nolu yapı ve MO çapraz sınıflandırma matrisi (GU=%67.5).

		MAKSİMUM OLABİLİRLİK											
EGPB	Sınıf	1	2	3	4	5	6	7	8	9	10	11	12
	1	0.138	0.011	0.003	0	0	0	0	0.003	0	0	0	0
	2	0.003	0.123	0.018	0.001	0	0	0.004	0.015	0	0	0	0
	3	0.001	0.04	0.11	0.001	0	0	0	0.113	0	0.007	0	0
	4	0	0	0	0.006	0	0	0	0.002	0	0	0	0
	5	0.001	0.001	0	0	0.001	0	0.001	0.001	0	0	0	0
	6	0	0	0	0	0	0.005	0	0	0	0	0	0
	7	0	0	0	0	0	0.002	0.015	0.007	0.001	0	0	0
	8	0	0	0.001	0.007	0	0	0	0.111	0	0.006	0	0
	9	0	0	0	0	0	0.001	0.001	0.018	0.07	0.004	0.003	0
	10	0	0	0	0.003	0	0	0	0.026	0.003	0.053	0.002	0
	11	0	0	0	0.001	0	0	0	0.001	0.003	0.003	0.021	0
	12	0.001	0	0	0	0	0.002	0	0.003	0	0	0	0.021

Tablo 6.39: EGPB yapılarının kendi içinde ve MO yöntemiyle olan uygunluk matrisi.

	MO	1	2	3	4	5	6	7	8	9
MO	100	53.9	61.7	60.4	62.6	63.9	67.5	66.4	66.5	66
1		100	75	72.6	78.9	77.7	72.9	71.5	69.3	70.5
2			100	83.8	88.1	87.7	82.2	78	74.7	74.1
3				100	82.3	82.9	76	75.1	72.4	73
4					100	92.2	83.7	80	76.4	77
5						100	83.6	80.5	77	78
6							100	85	80.8	81
7								100	83.7	84
8									100	83.8
9										100

6.7.1.6 Eşleştirmeli Gradyent Fletcher-Reeves Algoritması


EGFR algoritması ile gerçekleştirilen sınıflandırma uygulamalarında eğitim giriş vektörlerinin ağa verilmesi sıralı olarak gerçekleştirilmiştir. Bu algoritmayla elde edilen GD, Kappa ve MSE değerleri Tablo 6.40'da verilmektedir.

Tablo 6.40: EGFR algoritması ile elde edilen GD, Kappa ve MSE değerleri

YAPI NO	EĞİTİM VERİSİ			TEST VERİSİ			Epok
	GD	Kappa	MSE	GD	Kappa	MSE	
1	89.2	88.0	0.0222	84.3	82.2	0.0273	2500
2	91.3	90.3	0.0179	90.5	89.2	0.0205	2500
3	93.3	92.5	0.0142	88.8	87.3	0.0216	6300
4	93.8	93.1	0.0127	89.9	88.6	0.0197	11600
5	93.8	93.0	0.0129	89.0	87.5	0.0197	6200
6	90.5	89.4	0.0117	89.2	87.7	0.0165	3700
7	95.2	94.6	0.0083	90.3	89.1	0.0154	4000
8	96.2	95.7	0.0067	89.8	88.5	0.0153	3200
9	96.0	95.5	0.0070	90.1	88.8	0.0155	3900

EGFR algoritması ile gerçekleştirilen sınıflandırma uygulamaları sonucunda GD ölçütüne göre test verisi için en yüksek performansı sağlayan yapı 2 nolu yapı olarak

belirlenmiştir. Bu yapının eğitim süreci sırasında elde edilen GD-Epok ve MSE-Epok grafikleri Şekil 6.20’de gösterilmektedir. Bu yapı için elde edilen test verisi hata matrisi Tablo 6.41’de ve diğer yapılar için test verisi üretici doğruluk değerleri Tablo 6.42’de verilmektedir.



Şekil 6.20: EGFR kuralıyla 2 nolu MLP yapısında; (a) GD-Epok ve (b) MSE-Epok grafiği.


Eğitimde, test verisi GD ve MSE performans eğrileri birbiriyle tutarsızdır. GD ve MSE doğru orantılı olarak, GD artarken MSE artmış ve azalırken de azalmıştır. Bu da ağın örnek veriyi belirli bir oranda ezberlediği ve dolayısıyla genelleme yeteneğinde belirli bir azalmanın olduğu anlamına gelmektedir.

Tablo 6.41: EGFR 2 nolu yapının test verisi hata matrisi (GD=%90.5, Kappa=%89.2).

		REFERANS VERİ													
SINIFLANDIRILMIŞ VERİ	Sınıf	1	2	3	4	5	6	7	8	9	10	11	12	TP	KD
	1	659	19	0	0	2	0	0	0	0	0	0	0	680	96.9
	2	63	352	1	0	9	0	0	0	0	0	0	0	425	82.8
	3	0	18	239	0	0	0	1	1	0	10	0	0	269	88.8
	4	0	0	0	83	0	0	0	12	0	0	14	0	109	76.1
	5	0	0	0	0	149	0	0	0	0	0	0	0	149	100
	6	0	0	0	0	0	98	6	0	0	0	0	0	104	94.2
	7	0	0	0	0	0	15	123	0	3	0	0	0	141	87.2
	8	0	0	0	13	0	0	0	76	0	26	2	0	117	65
	9	0	0	2	0	0	19	1	0	305	5	19	0	351	86.9
	10	0	0	0	2	0	1	0	7	5	238	34	0	287	82.9
	11	0	0	0	5	0	1	0	4	10	17	408	0	445	91.7
	12	0	0	0	0	0	0	0	0	0	0	0	571	571	100
TP		722	389	242	103	160	134	131	100	323	296	477	571	3648	
ÜD		91.3	90.5	98.8	80.6	93.1	73.1	93.9	76	94.4	80.4	85.5	100		

Test verisi hata matrisine göre en düşük performans değerini 4, 6, 8, ve 10 nolu sınıflar vermiştir. 4 nolu sınıf 8 nolu sınıfı, 6 nolu sınıf 7 ve 9 nolu sınıflarla, 8 nolu sınıf 4 nolu sınıfı ve 10 nolu sınıf 8 ve 11 nolu sınıflarla karışım göstermektedir. EGFR algoritmasının eğitim ve test verileri için %85.6 ve %82.6 GD değerleriyle

ürettiği karar bölgeleri Şekil 6.21’de gösterilmektedir. MO yöntemine göre oldukça farklı bir sınıflandırma dağılımı görülmektedir. 1, 2, 5, 8, 9, 10 ve 12 nolu sınıflar birden fazla bölgede oluşmuştur. 8 nolu sınıf alansal olarak küçülmüştür. 10 ve 9 nolu sınıflar 4 nolu sınıfın bulunduğu bölgeye kaymıştır. Bu işlem için elde edilen hata matrisine göre de 6 nolu sınıf 9 ve 11 nolu sınıfla, 8 nolu sınıf 4 ve 10 nolu sınıfla ve 11 nolu sınıf 4, 9, ve 10 nolu sınıflarla karışım göstererek düşük doğruluk değerleri elde etmişlerdir.



Şekil 6.21: EGFR öğrenme kuralının ürettiği karar bölgeleri.

Tablo 6.42: EGFR yapılarının test verisi üretici doğruluk değerleri.

SINIF	MLP Yapı No								
	1	2	3	4	5	6	7	8	9
1	90.3	91.3	90.7	91.6	90.2	92.8	90.9	93.5	92.7
2	79.2	90.5	80.7	84.6	85.3	92.0	88.9	86.9	88.7
3	90.9	98.8	91.3	99.6	97.1	99.2	100	94.6	90.5
4	83.5	80.6	86.4	89.3	89.3	91.3	91.3	90.3	86.4
5	93.8	93.1	86.9	94.4	88.8	90.6	88.8	88.8	91.3
6	75.4	73.1	75.4	72.4	73.9	74.6	78.4	76.1	78.4
7	87	93.9	96.2	95.4	96.2	87.0	94.7	94.7	95.4
8	72.0	76.0	78.0	72.0	69.0	0.0	76.0	78.0	74.0
9	95.7	94.4	96.0	93.8	94.7	94.7	95.0	94.1	94.1
10	29.4	80.4	75.7	75.7	77.0	87.5	75.7	81.8	80.7
11	84.7	85.5	86.2	86.8	82.6	83.0	85.5	79.2	83.9
12	100	100	100	100	100	100	100	100	100

EGFR 2 nolu yapının MO yöntemiyle oluşturduğu çapraz sınıflandırma matrisi Tablo 6.43’de verilmektedir. MO ile olan en büyük uygunluk değerini veren sınıflar

5 ve 12 nolu sınıflardır. Tablo 6.44’de EGFR yapılarının kendi aralarında ve MO yöntemiyle olan genel uygunluk matrisleri verilmektedir. Buna göre, MO yöntemiyle en büyük genel uygunluk değerini 8 nolu yapı vermiştir.

Tablo 6.43: EGFR 2 nolu yapı ve MO çapraz sınıflandırma matrisi (GU=%59.1).

		MAKSİMUM OLABİLİRLİK											
EGFR	Sınıf	1	2	3	4	5	6	7	8	9	10	11	12
	1	0.135	0.024	0.004	0	0	0	0	0.004	0	0	0	0
	2	0.005	0.106	0.02	0	0	0	0.001	0.016	0	0	0	0
	3	0.001	0.043	0.105	0	0	0	0	0.131	0	0.007	0	0
	4	0	0	0	0.005	0	0	0	0	0	0	0	0
	5	0.002	0.001	0	0	0.001	0	0.002	0.002	0	0	0	0
	6	0	0	0	0	0	0.005	0.001	0	0	0	0	0
	7	0	0.001	0	0	0	0.001	0.017	0.034	0.002	0	0	0
	8	0	0	0.003	0.006	0	0	0	0.059	0	0.001	0	0
	9	0	0	0	0.001	0	0.001	0.001	0.017	0.066	0.011	0.003	0
	10	0	0	0	0.004	0	0	0	0.031	0.007	0.049	0.001	0
	11	0	0	0	0.002	0	0	0	0.003	0.003	0.005	0.022	0
	12	0	0	0	0	0	0.002	0	0.004	0	0	0	0.021

Tablo 6.44: EGFR yapılarının kendi içinde ve MO yöntemiyle olan uygunluk matrisi.

	MO	1	2	3	4	5	6	7	8	9
MO	100	56.9	59.1	62.1	63.5	62.7	58.4	65.9	69.1	66.2
1		100	71.8	75.1	74.6	75.6	64.7	73.9	70.5	73.4
2			100	80.7	79.2	81.9	68.7	79.2	76.4	75.8
3				100	86.7	88.6	68.2	79.2	79.7	79.2
4					100	88.1	68.2	81.5	79.8	80.7
5						100	69.9	82.3	81.8	81.9
6							100	74.6	73.7	73.5
7								100	85.9	83.8
8									100	86
9										100


6.7.1.7 Eşleştirmeli Gradyent Polak-Ribiere Algoritması

EGPR algoritması ile gerçekleştirilen sınıflandırma uygulamalarında eğitim giriş vektörlerinin ağı verilmesi sıralı olarak gerçekleştirilmiştir. Bu algoritmayla elde edilen GD, Kappa ve MSE değerleri Tablo 6.45’de verilmektedir.

Tablo 6.45: EGPR algoritması ile elde edilen GD, Kappa ve MSE değerleri

YAPI NO	EĞİTİM VERİSİ			TEST VERİSİ			Epok
	GD	Kappa	MSE	GD	Kappa	MSE	
1	91.1	90.0	0.0234	86.6	84.9	0.0280	2800
2	92.0	91.0	0.0166	86.1	84.3	0.0246	2600
3	93.4	92.6	0.0133	88.9	87.4	0.0206	4500
4	93.7	93.0	0.0137	88.5	87.0	0.0220	6000
5	93.9	93.2	0.0128	88.1	86.5	0.0229	6000
6	93.4	92.6	0.0109	89.5	88.1	0.0165	2500
7	95.8	95.3	0.0067	90.4	89.2	0.0147	4700
8	97.7	96.6	0.0050	90.2	88.9	0.0158	10000
9	95.6	95.1	0.0084	89.5	88.2	0.0165	2800

EGPR algoritması ile gerçekleştirilen sınıflandırma uygulamaları sonucunda GD ölçütüne göre test verisi için en yüksek performansı sağlayan yapı 7 nolu yapı olarak belirlenmiştir. Bu yapının eğitim süreci sırasında elde edilen GD-Epok ve MSE-Epok grafikleri Şekil 6.22'da gösterilmektedir. Bu yapı için elde edilen test verisi hata matrisi Tablo 6.46'da ve diğer yapılar için test verisi üretici doğruluk değerleri Tablo 6.47'de verilmektedir.




Şekil 6.22: EGPR kuralıyla 7 nolu MLP yapısında; (a) GD-Epok ve (b) MSE-Epok grafiği.

Eğitimde, test verisi GD ve MSE performans eğrileri birbiriyle tutarlı gerçekleşmiştir.

Tablo 6.46: EGPR 7 nolu yapının test verisi hata matrisi (GD=%90.4, Kappa=%89.2).

	Sınıf	REFERANS VERİ												TP	KD
		1	2	3	4	5	6	7	8	9	10	11	12		
SINIFLANDIRILMIŞ VERİ	1	666	10	0	0	0	0	0	0	0	0	0	0	676	98.5
	2	56	355	7	0	14	0	0	0	0	0	0	0	432	82.2
	3	0	24	235	0	0	0	0	0	0	10	0	0	269	87.4
	4	0	0	0	93	0	0	0	19	0	0	8	0	120	77.5
	5	0	0	0	0	146	0	0	0	0	0	0	0	146	100
	6	0	0	0	0	0	98	3	0	0	0	0	0	101	97
	7	0	0	0	0	0	17	126	0	5	0	1	0	149	84.6
	8	0	0	0	6	0	7	0	73	0	42	9	0	137	53.3
	9	0	0	0	0	0	10	2	0	307	8	14	0	341	90
	10	0	0	0	2	0	0	0	7	1	225	41	0	276	81.5
	11	0	0	0	2	0	2	0	1	10	11	404	0	430	94
	12	0	0	0	0	0	0	0	0	0	0	0	571	571	100
TP		722	389	242	103	160	134	131	100	323	296	477	571	3648	
ÜD		92.2	91.3	97.1	90.3	91.2	73.1	96.2	73	95	76	84.7	100		

Test verisi hata matrisine göre en düşük performans değerini 6, 8 ve 10 nolu sınıflar vermiştir. 6 nolu sınıf 7, 8, 9 nolu sınıflarla, 8 nolu sınıf 4 nolu sınıfla ve 10 nolu sınıfta 8 nolu sınıfla büyük ölçüde karışım göstermiştir. EGPR algoritmasının eğitim ve test verileri için %83.1 ve %80.6 GD ile ürettiği karar bölgeleri Şekil 6.23'de verilmektedir. MO yöntemine göre yine sınıfların çoğu birden fazla alanlarda oluşmuştur. 12 nolu sınıf orijine yakın konumunda tek bölge olarak oluşmuştur. 2, 3 ve 7 nolu sınıflar oldukça farklı bölgelere kaymışlardır. Bu işlemin hata matrisine göre 6, 8 ve 10 nolu sınıflar çok düşük doğruluk değerleri elde etmişlerdir. 6 nolu sınıf 9 ve 11 nolu sınıflarla, 8 nolu sınıf 4, 10 ve 11 nolu sınıflarla ve 10 nolu sınıf 8 ve 11 nolu sınıflarla karışım göstermiştir. Özellikle 10 nolu sınıf verisinden 8 nolu sınıfa atanan piksel sayısı çok büyük bir orana sahiptir. Buda 8 nolu sınıfın kullanıcı doğruluk değerinin çok fazla düşmesine neden olmuştur.



Şekil 6.23: EGPR öğrenme kuralının ürettiği karar bölgeleri.

Tablo 6.47: EGPR yapılarının test verisi üretici doğruluk değerleri.

SINIF	MLP Yapı No								
	1	2	3	4	5	6	7	8	9
1	89.1	88.5	90.3	90.3	90.2	93.8	92.2	93.1	91.6
2	76.6	74.8	85.3	81.0	82.5	88.7	91.3	90.5	85.6
3	89.7	74.8	97.9	93.0	93.8	90.1	97.1	95.9	96.3
4	94.2	82.5	93.2	90.3	91.3	89.3	90.3	90.3	93.2
5	91.9	92.5	88.1	93.1	93.1	91.3	91.3	91.9	93.1
6	68.7	73.9	71.6	76.9	74.6	77.6	73.1	68.7	77.6
7	90.8	95.4	96.2	96.2	94.7	95.4	96.2	97.7	95.4
8	53.0	66.0	67.0	72.0	72.0	82.0	73.0	69.0	81.0
9	97.2	95.0	95.4	94.7	92.0	91.6	95.0	93.5	94.1
10	65.5	74.7	77.7	74.7	76.0	72.0	76.0	78.4	77.4
11	86.8	85.3	80.9	83.0	80.1	83.0	84.7	83.6	79.7
12	100	100	100	100	100	100	100	100	100

EGPR 7 nolu yapının MO yöntemiyle olan çapraz sınıflandırma matrisi Tablo 6.48’de verilmektedir. MO yöntemiyle en yüksek uygunluk değerini veren sınıflar 5 ve 12 nolu sınıflardır. Tablo 6.49’da EGPR yapılarının kendi aralarında ve MO yöntemiyle olan genel uygunluk değerleri verilmiştir. MO yöntemiyle en yüksek genel uygunluk değerini veren yapı 8 nolu yapıdır.

Tablo 6.48: EGPR 7 nolu yapı ve MO çapraz sınıflandırma matrisi (GU=%65.7).

	Sınıf	MAKSİMUM OLABİLİRLİK											
		1	2	3	4	5	6	7	8	9	10	11	12
EGPR	1	0.138	0.012	0.002	0	0	0	0	0.003	0	0	0	0
	2	0.004	0.129	0.021	0.001	0	0	0.002	0.045	0	0	0	0
	3	0	0.033	0.107	0	0	0	0	0.083	0	0.005	0	0
	4	0	0	0	0.007	0	0	0	0.001	0	0	0	0
	5	0	0.001	0	0	0.001	0	0.001	0.001	0	0	0	0
	6	0	0	0	0	0	0.005	0	0	0	0	0	0
	7	0	0	0	0	0	0.002	0.017	0.01	0.001	0	0	0
	8	0	0	0.001	0.006	0	0.001	0	0.09	0.001	0.006	0	0
	9	0	0	0	0.001	0	0.001	0.001	0.027	0.071	0.006	0.004	0
	10	0	0	0	0.003	0	0	0	0.035	0.001	0.053	0.002	0
	11	0	0	0	0.001	0	0	0	0.003	0.004	0.002	0.02	0
	12	0.001	0	0	0	0	0.002	0	0.003	0	0	0	0.021

Tablo 6.49: EGPR yapılarının kendi içinde ve MO yöntemiyle olan uygunluk matrisi.

	MO	1	2	3	4	5	6	7	8	9
MO	100	61.3	61.1	62.7	61.9	63.2	65.8	65.7	68.2	67.2
1		100	87.1	80.7	81.5	82.5	68.7	76.2	70.7	79.9
2			100	81.7	83.1	84.6	69.8	76.6	72.1	81.4
3				100	87.8	90.1	75.5	80.1	75.9	84.5
4					100	89.8	73.7	81.4	76.5	86.4
5						100	75.9	81.4	76.5	87
6							100	78.7	78.2	78.4
7								100	82.7	85.6
8									100	80.8
9										100

6.7.1.8 Tek Adım Sekant Algoritması


TAS algoritması ile gerçekleştirilen sınıflandırma uygulamalarında eğitim giriş vektörlerinin ağı verilmesi sıralı olarak gerçekleştirilmiştir. Bu algoritmayla elde edilen GD, Kappa ve MSE değerleri Tablo 6.50’de verilmektedir.

Tablo 6.50: TAS algoritması ile elde edilen GD, Kappa ve MSE değerleri

YAPI NO	EĞİTİM VERİSİ			TEST VERİSİ			Epok
	GD	Kappa	MSE	GD	Kappa	MSE	
1	92.2	91.3	0.0152	89.9	88.6	0.0199	24600
2	92.4	91.6	0.0144	88.2	86.6	0.0204	27900
3	92.7	91.8	0.0143	89.1	87.7	0.0199	9900
4	94.3	93.6	0.0115	88.6	87.2	0.0206	33200
5	94.0	93.4	0.0118	89.7	87.8	0.0201	27400
6	95.5	95.0	0.0069	90.0	88.7	0.0147	7800
7	95.3	94.8	0.0077	90.8	89.6	0.0150	9500
8	95.7	95.2	0.0080	90.1	88.8	0.0154	8300
9	96.0	95.6	0.0075	90.8	89.6	0.0145	10700

TAS algoritması ile gerçekleştirilen sınıflandırma uygulamaları sonucunda GD ölçütüne göre test verisi için en yüksek performansı daha küçük epok değerinde

sağlayan YSA yapısı 7 nolu yapı olarak belirlenmiştir. Bu yapının eğitim süreci sırasında elde edilen GD-Epok ve MSE-Epok grafikleri Şekil 6.24’de gösterilmektedir. Bu yapı için elde edilen test verisi hata matrisi de Tablo 6.51’de ve diğer yapıların test verisi üretici doğruluk değerleri Tablo 6.52’de verilmektedir.



Şekil 6.24: TAS kuralıyla 7 nolu MLP yapısında; (a) GD-Epok ve (b) MSE-Epok grafiği.


Eğitimde, test verisi GD ve MSE performans eğrileri birbiriyle tutarlı gerçekleşmiştir.

Tablo 6.51: TAS 7 nolu yapının test verisi hata matrisi (GD=%90.8, Kappa=%89.6).

		REFERANS VERİ													
SINIFLANDIRILMIŞ VERİ	Sınıf	1	2	3	4	5	6	7	8	9	10	11	12	TP	KD
	1	665	21	0	0	0	0	0	0	0	0	0	0	686	96.9
	2	57	344	0	0	9	0	0	0	0	0	0	0	410	83.9
	3	0	24	242	0	0	0	4	0	0	4	0	0	274	88.3
	4	0	0	0	96	0	0	0	9	0	1	11	0	117	82.1
	5	0	0	0	0	151	0	0	0	0	0	0	0	151	100
	6	0	0	0	0	0	103	2	0	0	0	1	0	106	97.2
	7	0	0	0	0	0	12	123	0	2	0	0	0	137	89.8
	8	0	0	0	6	0	3	0	83	2	42	12	0	148	56.1
	9	0	0	0	0	0	14	2	0	309	10	19	0	354	87.3
	10	0	0	0	0	0	0	0	8	0	229	37	0	274	83.6
	11	0	0	0	1	0	2	0	0	10	10	397	0	420	94.5
	12	0	0	0	0	0	0	0	0	0	0	0	571	571	100
TP		722	389	242	103	160	134	131	100	323	296	477	571	3648	
ÜD		92.1	88.4	100	93.2	94.4	76.9	93.9	83	95.7	77.4	83.2	100		

Test verisi hata matrisine göre en düşük performans değerlerini 6 ve 10 nolu sınıflar vermişlerdir. 6 nolu sınıf 7 ve 9 nolu sınıflarla ve 10 nolu sınıf 8 nolu sınıfla karışmıştır. TAS algoritmasının eğitim ve test verileri için %83.0 ve %81.0 GD ile ürettiği karar bölgeleri Şekil 6.25’de verilmektedir. MO yöntemine göre ilk göze çarpan 1 nolu sınıf alanındaki değişimdir. Bu sınıfa ikinci bir alan olarak x eksenine dayalı yüksek parlaklık seviyelerinde yeni bir bölge oluşmuştur. 11 nolu sınıf alanı

büyümüş ve 8 nolu sınıf küçülmüştür. 4 nolu sınıf alanı da köşegen formundan uzaklaşıp y eksenine paralel daha geniş bir alana dağılmıştır. Bu işlemin hata matrisine göre 6 ve 10 nolu sınıflar çok düşük doğruluk değerine sahiptir. 6 nolu sınıf 7, 9 ve 11 nolu sınıflarla ve 10 nolu sınıf ise 3, 8 ve 11 nolu sınıflarla büyük ölçüde karışım göstermiştir.



Şekil 6.25: TAS öğrenme kuralının ürettiği karar bölgeleri.

Tablo 6.52: TAS yapılarının test verisi üretici doğruluk değerleri.

SINIF	MLP Yapı No								
	1	2	3	4	5	6	7	8	9
1	89.3	91.7	90.4	89.8	90.6	92.7	92.1	90.7	90.9
2	93.1	89.7	87.9	84.8	86.4	90.7	88.4	89.7	90.0
3	99.2	99.2	99.6	96.3	97.1	96.7	100	94.2	100
4	83.5	82.5	81.6	88.3	86.4	91.3	93.2	95.1	90.3
5	93.8	88.1	89.4	90.0	93.8	95.6	94.4	91.9	91.3
6	68.7	71.6	73.1	73.9	79.1	71.6	76.9	74.6	84.3
7	94.7	95.4	94.7	95.4	96.9	94.7	93.9	96.2	98.5
8	70.0	52.0	68.0	74.0	64.0	73.0	83.0	75.0	76.0
9	92.9	92.9	95.0	92.0	94.1	92.6	95.7	94.1	94.1
10	84.1	62.8	69.3	76.0	75.0	77.4	77.4	79.4	78.0
11	81.6	86.0	86.8	83.0	82.8	81.3	83.2	83.2	83.9
12	100	100	100	100	100	100	100	100	100

TAS 7 nolu yapının MO yöntemiyle elde ettiği çapraz sınıflandırma matrisi Tablo 6.53'de verilmiştir. MO yöntemiyle en yüksek uygunluk değerini veren sınıflar 5 ve 12 nolu sınıflardır. Tablo 6.54'de TAS yapılarının kendi aralarında ve MO

yöntemiyle olan genel uygunluk değerleri verilmektedir. Bu değerlere göre MO yöntemiyle en yüksek genel uygunluk değerini veren yapı 6 nolu yapıdır.

Tablo 6.53: TAS 7 nolu yapı ve MO çapraz sınıflandırma matrisi (GU=%66.6).

		MAKSİMUM OLABİLİRLİK											
TAS	Sınıf	1	2	3	4	5	6	7	8	9	10	11	12
	1	0.137	0.017	0.004	0	0	0	0	0.002	0	0	0	0
	2	0.005	0.113	0.015	0	0	0	0.001	0.023	0	0	0	0
	3	0	0.042	0.112	0.001	0	0	0	0.112	0	0.003	0	0
	4	0	0	0	0.006	0	0	0	0.001	0	0	0	0
	5	0.001	0.002	0.001	0	0.001	0	0.002	0.002	0	0	0	0
	6	0	0	0	0	0	0.005	0	0	0	0	0	0
	7	0	0	0	0	0	0.001	0.016	0.006	0.001	0	0	0
	8	0	0	0.001	0.008	0	0.001	0	0.108	0	0.006	0.001	0
	9	0	0	0	0.001	0	0.001	0.001	0.012	0.072	0.007	0.003	0
	10	0	0	0	0.003	0	0	0	0.031	0.001	0.054	0.001	0
	11	0	0	0	0.001	0	0	0	0.001	0.003	0.003	0.021	0
	12	0.001	0	0	0	0	0.002	0	0.004	0	0	0	0.021

Tablo 6.54: TAS yapılarının kendi içinde ve MO yöntemiyle olan uygunluk matrisi.

	MO	1	2	3	4	5	6	7	8	9
MO	100	62.8	63	62.5	64.3	64.5	69.9	66.6	66.5	68.2
1		100	79.2	80.7	81.3	80	76.9	80.5	80.7	79.3
2			100	88.4	84.6	85.2	74.2	79.6	78.7	79.2
3				100	88.4	87.2	74.7	83.2	81.8	82.6
4					100	86.9	77.5	83.9	85.7	83.8
5						100	76.8	84.8	85	84.6
6							100	79.8	80.8	82.5
7								100	85.3	85.9
8									100	89.2
9										100


6.7.1.9 Esnek Geri Yayılma Öğrenme Algoritması

Esnek geri yayılma öğrenme algoritmasında kullanılan ağırlık değişimi artırma parametresi (η^+) 1.2 ve ağırlık değişimi azaltma parametresi (η^-) 0.5 olarak belirlenmiştir. Ayrıca başlangıç ağırlık değişimi (Δ_0) parametresi de 0.07 olarak belirlenmiştir. Bu değerlerin, yapılan bir çok deneme sonucunda ilgilenilen sınıflandırma problemi için optimal değerler oldukları gözlenmiştir. EG algoritması ile gerçekleştirilen sınıflandırma uygulamalarında eğitim giriş vektörlerinin ağırlık verilmesi sıralı olarak gerçekleştirilmiştir. Bu algoritmayla elde edilen GD, Kappa ve MSE değerleri Tablo 6.55’de verilmektedir.

Tablo 6.55: EG algoritması ile elde edilen GD, Kappa ve MSE değerleri

YAPI NO	EĞİTİM VERİSİ			TEST VERİSİ			Epok
	GD	Kappa	MSE	GD	Kappa	MSE	
1	91.7	90.7	0.0203	87.8	86.2	0.0262	9000
2	90.9	89.8	0.0200	86.9	85.2	0.0258	9400
3	90.8	89.7	0.0206	87.1	85.4	0.0255	10800
4	91.3	90.3	0.0199	88.5	86.9	0.0249	13100
5	91.3	91.0	0.0199	88.5	86.5	0.0249	13200
6	92.9	92.1	0.0137	89.3	87.9	0.0199	5000
7	93.6	92.9	0.0101	90.1	88.9	0.0156	14000
8	93.0	92.2	0.0118	90.8	89.6	0.0159	6300
9	96.1	95.7	0.0072	91.4	90.3	0.0167	10900

EG algoritması ile gerçekleştirilen sınıflandırma uygulamaları sonucunda GD ölçütüne göre test verisi için en yüksek performansı sağlayan yapı 9 nolu yapı olarak belirlenmiştir. Bu yapının eğitim süreci sırasında elde edilen GD-Epok ve MSE-Epok grafikleri Şekil 6.26'de gösterilmektedir. Bu yapı için elde edilen test verisi hata matrisi de Tablo 6.56'da ve diğer yapılar için test verisi üretici doğruluk değerleri Tablo 6.57'de verilmektedir.




Şekil 6.26: EG kurallıyla 9 nolu MLP yapısında; (a) GD-Epok ve (b) MSE-Epok grafiği.

Eğitimde, test verisi GD ve MSE performans eğrileri birbiriyle tutarlı gerçekleşmiştir.

Tablo 6.56: EG 9 nolu yapının test verisi hata matrisi (GD=%91.4, Kappa=%90.3).

	Sınıf	REFERANS VERİ												TP	KD
		1	2	3	4	5	6	7	8	9	10	11	12		
SINIFLANDIRILMIŞ VERİ	1	679	8	0	0	0	0	0	0	0	0	0	0	687	98.8
	2	43	360	1	1	16	0	0	0	0	1	0	0	422	85.3
	3	0	21	241	0	0	0	0	0	1	3	0	0	266	90.6
	4	0	0	0	96	0	0	0	20	0	1	7	0	124	77.4
	5	0	0	0	0	144	0	0	0	0	1	0	0	145	99.3
	6	0	0	0	0	0	116	3	0	3	0	2	0	124	93.5
	7	0	0	0	0	0	6	126	0	2	1	0	0	135	93.3
	8	0	0	0	5	0	4	0	71	1	26	14	0	121	58.7
	9	0	0	0	0	0	6	2	0	299	8	14	0	329	90.9
	10	0	0	0	0	0	0	0	8	1	241	50	0	300	80.3
	11	0	0	0	1	0	2	0	1	16	14	390	0	424	92
	12	0	0	0	0	0	0	0	0	0	0	0	571	571	100
TP		722	389	242	103	160	134	131	100	323	296	477	571	3648	
ÜD		94	92.5	99.6	93.2	90	86.6	96.2	71	92.6	81.4	81.8	100		

Test verisi hata matrisine göre en düşük performans değerlerini veren sınıflar 8, 10 ve 11 nolu sınıflardır. 8 nolu sınıf 4 nolu sınıfla, 10 nolu sınıf 8 ve 11 nolu sınıflarla ve 11 nolu sınıf 10 nolu sınıfla büyük ölçüde karışmıştır. EG yönteminin eğitim ve test verileri için %85 ve %83.1 GD ile ürettiği karar bölgeleri Şekil 6.27’de verilmektedir. MO’ya göre 1 nolu sınıfın yeni oluşan ikinci bölgesi köşegenin tepe noktasına 4 nolu sınıfın oluşturduğu bölgenin içine kaymıştır. 8 nolu sınıf oldukça küçülürken 6 nolu sınıf sağ alt tarafta oldukça büyük bir bölge oluşturmuştur. Bu işlemin hata matrisine göre 6 ve 8 nolu sınıflar 9, 11 ve 4 nolu sınıflarla karışım göstermektedirler.



Şekil 6.27: EG öğrenme kuralının ürettiği karar bölgeleri.

Tablo 6.57: EG yapılarının test verisi üretici doğruluk değerleri.

SINIF	MLP YAPISI NO								
	1	2	3	4	5	6	7	8	9
1	89.8	88.8	89.9	90.3	91.7	89.2	92.2	93.2	94.0
2	80.2	76.1	74.6	77.1	81.0	87.4	88.9	91.3	92.5
3	91.3	93.0	88.0	88.0	88.8	99.2	99.2	99.6	99.6
4	81.6	91.3	95.1	91.3	87.4	87.4	93.2	92.2	93.2
5	91.9	92.5	95.6	93.8	93.8	91.3	93.1	90.0	90.0
6	76.1	79.1	74.6	84.3	72.4	85.8	72.4	77.6	86.6
7	94.7	91.6	96.2	94.7	96.2	89.3	96.9	97.7	96.2
8	70.0	57.0	73.0	77.0	72.0	72.0	78.0	73.0	71.0
9	94.7	93.8	94.1	94.1	92.9	92.9	94.7	94.1	92.6
10	66.9	71.6	64.5	73.0	69.9	74.7	74.3	76.4	81.4
11	87.8	83.4	85.7	86.6	85.5	84.3	82.2	83.6	81.8
12	100	100	100	100	100	100	100	100	100

EG 9 nolu yapının MO yöntemiyle oluşturduğu çapraz sınıflandırma matrisi Tablo 6.58’de verilmektedir. MO yöntemiyle en yüksek uygunluk değerinin veren sınıflar 5 ve 12 nolu sınıflardır. Tablo 6.59’da EG yapılarının hem kendi aralarında hem de MO yöntemiyle olan genel uygunluk değerleri verilmektedir. Buna göre MO yöntemiyle en büyük genel uygunluk değerini veren yapı 7 nolu yapıdır.

Tablo 6.58: EG 9 nolu yapı ve MO çapraz sınıflandırma matrisi (GU=%65).

	Sınıf	MAKSİMUM OLABİLİRLİK											
		1	2	3	4	5	6	7	8	9	10	11	12
EG	1	0.138	0.01	0.002	0	0	0	0	0.003	0	0	0	0
	2	0.004	0.121	0.019	0	0	0	0.001	0.031	0	0.002	0	0
	3	0	0.043	0.109	0	0	0	0	0.084	0	0.005	0	0
	4	0	0	0	0.006	0	0	0	0.002	0	0	0	0
	5	0.001	0.001	0	0.001	0.001	0	0.003	0.004	0	0	0	0
	6	0	0	0	0	0	0.006	0.001	0.004	0.001	0	0	0
	7	0	0	0	0	0	0.001	0.015	0.015	0	0.001	0	0
	8	0	0	0	0.007	0	0	0	0.095	0.001	0.009	0	0
	9	0	0	0	0	0	0	0	0.016	0.069	0.004	0.003	0
	10	0	0	0.001	0.002	0	0	0	0.04	0	0.047	0.001	0
	11	0	0	0	0.002	0	0	0	0.005	0.006	0.004	0.022	0
	12	0	0	0	0	0	0.002	0	0.002	0	0	0	0.021

Tablo 6.59: EG yapılarının kendi içinde ve MO yöntemiyle olan uygunluk matrisi.

	MO	1	2	3	4	5	6	7	8	9
MO	100	60.9	57	58.3	57.9	60.4	63.6	66.1	64.9	65
1		100	80.4	84.6	82.7	85	81.4	73.9	72.4	73.8
2			100	82.2	85.1	83.8	80.9	72.2	73.2	74
3				100	87.5	84.8	78.5	69.9	72	72.8
4					100	85.4	80	70.6	72.9	73.3
5						100	82.2	75.6	74.6	75.1
6							100	78.7	78.4	78
7								100	80	78.7
8									100	78.5
9										100


6.7.1.10 Ölçeklendirilmiş Eşleştirmeli Gradyent Algoritması

Ölçeklendirilmiş Eşleştirmeli Gradyent algoritması için ölçekleme parametresi (λ) başlangıç değeri 5.10^{-7} olarak belirlenmiştir. ÖEG algoritması ile gerçekleştirilen sınıflandırma uygulamalarında eğitim giriş vektörlerinin ağı verilmesi sıralı olarak gerçekleştirilmiştir. Bu algoritmayla elde edilen GD, Kappa ve MSE değerleri Tablo 6.60'da verilmektedir.

Tablo 6.60: ÖEG algoritması ile elde edilen GD, Kappa ve MSE değerleri

YAPI NO	EĞİTİM VERİSİ			TEST VERİSİ			Epok
	GD	Kappa	MSE	GD	Kappa	MSE	
1	89.2	87.9	0.0222	85.2	83.3	0.0277	1400
2	91.0	90.0	0.0201	88.0	86.4	0.0236	1000
3	92.2	91.3	0.0173	89.4	88.0	0.0231	1900
4	92.7	91.8	0.0154	89.9	88.6	0.0215	2600
5	92.9	92.0	0.0131	89.1	87.7	0.0196	3900
6	93.5	92.7	0.0106	89.5	88.2	0.0163	1600
7	95.2	94.7	0.0083	89.5	88.1	0.0160	2300
8	93.6	92.9	0.0125	89.8	88.4	0.0191	900
9	95.2	94.6	0.0091	90.3	89.1	0.0160	2000

ÖEG algoritması ile gerçekleştirilen sınıflandırma uygulamaları sonucunda GD ölçütüne göre test verisi için en yüksek performansı sağlayan yapı 9 nolu yapı olarak belirlenmiştir. Bu yapının eğitim süreci sırasında elde edilen GD-Epok ve MSE-Epok grafikleri Şekil 6.28’de gösterilmektedir. Bu yapı için elde edilen test verisi hata matrisi de Tablo 6.61’de ve diğer yapılar için üretici doğruluk değerleri Tablo 6.62’de verilmektedir.



Şekil 6.28: ÖEG kuralıyla 9 nolu MLP yapısında; (a) GD-Epok ve (b) MSE-Epok grafiği.


Eğitimde test verisi GD ve MSE performans eğrileri birbiriyle tutarlı gerçekleşmiştir.

Tablo 6.61: ÖEG 9 nolu yapının test verisi hata matrisi (GD=%90.3, Kappa=%89.1).

		REFERANS VERİ													
Sınıf		1	2	3	4	5	6	7	8	9	10	11	12	TP	KD
SINIFLANDIRILMIŞ VERİ	1	661	16	0	0	0	0	0	0	0	0	0	0	677	97.6
	2	61	348	0	0	11	0	0	0	0	0	0	0	420	82.9
	3	0	25	242	0	0	0	0	0	0	9	0	0	276	87.7
	4	0	0	0	93	0	0	0	20	0	0	21	0	134	69.4
	5	0	0	0	0	149	0	0	0	0	0	0	0	149	100
	6	0	0	0	0	0	108	3	0	0	0	4	0	115	93.9
	7	0	0	0	0	0	12	127	0	3	0	0	0	142	89.4
	8	0	0	0	6	0	2	0	69	2	37	7	0	123	56.1
	9	0	0	0	0	0	11	1	0	305	8	12	0	337	90.5
	10	0	0	0	3	0	0	0	11	1	231	42	0	288	80.2
	11	0	0	0	1	0	1	0	0	12	11	391	0	416	94
	12	0	0	0	0	0	0	0	0	0	0	0	571	571	100
TP		722	389	242	103	160	134	131	100	323	296	477	571	3648	
ÜD		91.6	89.5	100	90.3	93.1	80.6	96.9	69	94.4	78	82	100		

Test verisi hata matrisine göre en düşük performans gösteren sınıflar 6, 8, 10 ve 11 nolu sınıflardır. 6 nolu sınıf 7 ve 9 nolu sınıflarla, 8 nolu sınıf 4 ve 10 nolu sınıflarla, 10 nolu sınıf 8 nolu sınıfla ve 11 nolu sınıfta 10 ve 4 nolu sınıflarla önemli ölçüde karışım göstermiştir. ÖEG algoritmasının eğitim ve test verileri için %83.6 ve %81.3 GD ile ürettiği karar bölgeleri Şekil 6.29’da verilmektedir. MO’ya göre 8 nolu sınıfın

küçülmesine karşın 4 nolu sınıf çok büyümüştür. 1 nolu sınıf sol taraftaki konumunda 2 nolu sınıf tarafından sıkıştırılıp küçültülmüştür. 2 ve 3 nolu sınıfların da x eksenine dayalı olarak oluşturdukları yeni bölgelerde kapladıkları alanlar genişlemiştir. Bu işlemin test verisi hata matrisine göre 6, 8 ve 10 nolu sınıflar düşük performans göstermişlerdir. 6 nolu sınıf 9 ve 11 nolu sınıflarla, 8 nolu sınıf 4 ve 11 nolu sınıflarla ve 10 nolu sınıf ise 3, 11 nolu sınıflarla ve özellikle 8 nolu sınıfla büyük ölçüde karışım göstermişlerdir.



Şekil 6.29: ÖEG öğrenme kuralının ürettiği karar bölgeleri.

Tablo 6.62: ÖEG yapılarının test verisi üretici doğruluk değerleri.

SINIF	MLP Yapı No								
	1	2	3	4	5	6	7	8	9
1	88.9	91.3	89.5	90.6	90.3	90.0	91.4	91.8	91.6
2	68.9	74.3	87.4	89.2	88.2	90.5	87.4	88.2	89.5
3	83.1	99.2	91.7	97.5	95.9	99.6	94.6	99.2	100
4	85.4	77.7	94.2	91.3	86.4	93.2	91.3	85.4	90.3
5	95.0	93.8	94.4	93.1	93.1	91.3	92.5	88.8	93.1
6	75.4	73.1	77.6	79.1	76.9	86.6	78.4	74.6	80.6
7	93.1	91.6	93.9	96.9	96.2	96.9	92.4	97.7	96.9
8	47.0	58.0	62.0	70.0	74.0	70.0	75.0	66.0	69.0
9	96.9	94.4	96.6	96.6	92.6	93.5	94.4	93.5	94.4
10	63.2	72.6	73.3	70.9	75.3	68.2	76.7	74.3	78.0
11	87.2	88.9	87.2	84.5	81.6	82.4	81.3	86.4	82.0
12	100	100	100	100	100	100	100	100	100

ÖEG 9 nolu yapının MO yöntemiyle oluşturduğu çapraz sınıflandırma matrisi Tablo 6.63’de verilmektedir. MO yöntemiyle en yüksek uygunluk değerini 5 ve 12 nolu

sınıflar vermektedir. Tablo 6.64’de ÖEG yapılarının hem kendi aralarında hem de MO yöntemiyle olan genel uygunluk matrisleri verilmektedir. MO yöntemiyle en yüksek genel uygunluk matrisini veren yapı 9 nolu yapıdır.

Tablo 6.63: ÖEG 9 nolu yapı ve MO çapraz sınıflandırma matrisi (GU=%66.1).


		MAKSİMUM OLABİLİRLİK											
ÖEG	Sınıf	1	2	3	4	5	6	7	8	9	10	11	12
	1	0.139	0.012	0.004	0	0	0	0	0.004	0	0	0	0
	2	0.003	0.119	0.017	0.001	0	0	0.001	0.026	0	0	0	0
	3	0.001	0.041	0.11	0	0	0	0	0.124	0	0.008	0	0
	4	0	0	0	0.007	0	0	0	0.002	0	0	0	0
	5	0	0.002	0	0	0.001	0	0.002	0.001	0	0	0	0
	6	0	0	0	0	0	0.006	0.001	0.001	0	0	0	0
	7	0	0	0	0	0	0.001	0.016	0.008	0.001	0	0	0
	8	0	0	0.001	0.006	0	0	0	0.097	0.001	0.004	0	0
	9	0	0	0	0.001	0	0.001	0.001	0.012	0.07	0.006	0.003	0
	10	0	0	0	0.004	0	0	0	0.021	0.002	0.053	0.002	0
	11	0	0	0	0.001	0	0	0	0.002	0.003	0.002	0.021	0
	12	0	0	0	0	0	0.002	0	0.003	0	0	0	0.021

Tablo 6.64: ÖEG yapılarının kendi içinde ve MO yöntemiyle olan uygunluk matrisi.


	MO	1	2	3	4	5	6	7	8	9
MO	100	56.3	55.8	60.9	62	61.6	64.8	64.8	65.8	66.1
1		100	78.2	85.3	82.8	82.6	71.4	77.7	77.8	77.7
2			100	81.1	80.8	81.2	68.7	75.2	78.1	78.7
3				100	90.3	87.5	75.6	80.3	83.2	83.2
4					100	89.7	78.5	82.4	86.8	86.5
5						100	76.5	82.1	86.3	85.1
6							100	79.6	80.3	80.2
7								100	83.9	86.3
8									100	89.8
9										100

6.7.2. LVQ YSA Yapısı Uygulaması

LVQ YSA yapısı uygulaması, standart LVQ yapısının dezavantajlarını ortadan kaldıran LVQ1 ve LVQ2 algoritmalarının birlikte kullanılmasıyla gerçekleştirilmiştir. LVQ1 ve LVQ2 için başlangıç öğrenme oranları sırasıyla 0.3 ve 0.15 olarak belirlenmiştir. LVQ2 genişlik parametresi 0.15 olarak, cezalandırma (conscience) parametresi de 1 olarak belirlenmiştir. Giriş vektörlerinin ağa verilmesi sıralı olarak yapılmıştır. LVQ YSA mimarisi ile gerçekleştirilen sınıflandırma uygulamaları sonucunda test verisi GD ölçütüne göre en yüksek performansı sağlayan YSA yapısı 3 nolu yapı olarak belirlenmiştir (Tablo 6.65). Bu YSA yapısının eğitim süreci sırasında elde edilen GD-Epok ve MSE-Epok grafikleri Şekil 6.30’de ve Şekil 6.31’de verilmektedir.



Şekil 6.30: Eğitim ve test verisi sınıflandırma doğruluklarının ara katman işlemci eleman sayısı ile olan gösterimi.



Şekil 6.31: Eğitim ve test verisi MSE değerlerinin ara katman işlemci eleman sayısı ile olan gösterimi.

Test verisi GD ve MSE performans eğrileri, MLP öğrenme algoritmalarından elde edilen sonuçlara göre daha kesin bir şekilde sadece eğimsel olarak değil sayısal olarak da birbiriyle tutarlı olmuştur. Bu durum LVQ YSA yapısının çıkış uzayının 0 ve 1 ayrık değerlerinden oluşmasından kaynaklanmıştır. Böylece LVQ ağına çıkış uzayı doğrudan belirlenmiş sınıflardan oluşmaktadır. Buna karşılık MLP çıkış uzayı 0 ve 1 değerleri arasında sürekli bir uzay olup, sonuç sınıflar kazanan hepsini alır tekniğiyle elde edilmiştir.

Tablo 6.65: LVQ YSA mimari yapısıyla elde edilen GD, Kappa ve MSE değerleri


YAPI No	EĞİTİM VERİSİ			TEST VERİSİ			Epok
	GD	Kappa	MSE	GD	Kappa	MSE	
1	74.6	71.4	0.042400	75.4	72.1	0.041087	42
2	88.2	86.8	0.019656	86.8	85	0.022052	66
3	93.7	92.9	0.010547	89.8	88.5	0.017004	70
4	94.7	94	0.008893	89.2	87.8	0.018036	46
5	94.3	93.7	0.009448	88.2	86.7	0.019656	32
6	96.5	96.1	0.005883	88.8	87.4	0.018632	59
7	96.3	95.8	0.006225	88.9	87.5	0.018469	48
8	96.6	96.2	0.005685	88.2	86.7	0.019684	69
9	96.9	96.6	0.005141	88.9	87.5	0.018496	57
10	96.8	96.5	0.005271	88.6	87.2	0.018961	40
11	97.2	96.8	0.004720	88.7	87.2	0.018879	124
12	94.6	94	0.008968	87.6	86	0.020650	20
13	96.9	96.6	0.005141	88.3	86.8	0.019516	34
14	96.9	96.5	0.005198	88.4	86.9	0.019377	37
15	96.9	96.6	0.005141	88.3	86.8	0.019460	55
16	97.2	96.9	0.004651	88.2	86.7	0.019600	35
17	95.2	94.6	0.008082	87.5	86	0.020794	16
18	97.6	97.3	0.003969	88.4	86.9	0.019377	40
19	95	94.5	0.008281	88.7	87.2	0.018906	11
20	95.5	95	0.007534	88.1	86.6	0.019825	16
21	96.1	95.7	0.006432	88.3	86.9	0.019404	22
22	95.6	95.1	0.007259	87.9	86.4	0.020136	11
23	95.6	95.1	0.007259	88	86.5	0.019966	13
24	95.1	94.6	0.008154	88.3	86.8	0.019544	11

Uygulamada en büyük test verisi sınıflandırma doğruluk değeri KOHONEN ara katmanında 36 işlemci eleman bulunan 3 nolu ağ yapısından elde edilmiştir. Bu yapıda her bir sınıf için 3 referans vektörü görevlendirilmiştir. Tablo 6.66'da bu topolojiye sahip LVQ ağının ürettiği test verisi hata matrisi ve Tablo 6.67'de ise diğer yapılar için test verisi üretici doğruluk değerleri verilmektedir.

Tablo 6.66: LVQ 3 nolu yapı test verisi hata matrisi (GD=89.8, Kappa=88.5).

SINIF	REFERANS VERİ												TPS	KD
	1	2	3	4	5	6	7	8	9	10	11	12		
1	673	14	0	0	0	0	0	0	0	0	0	0	687	98
2	49	343	1	0	5	0	0	0	0	0	0	0	398	86.2
3	0	26	241	0	0	0	0	0	0	10	0	0	277	87
4	0	0	0	91	0	0	0	14	0	2	29	0	136	66.9
5	0	6	0	0	155	1	0	0	0	0	0	0	162	95.7
6	0	0	0	0	0	98	3	0	1	0	12	0	114	86
7	0	0	0	0	0	16	126	0	0	0	0	0	142	88.7
8	0	0	0	8	0	5	1	73	0	25	6	0	118	61.9
9	0	0	0	0	0	13	1	0	286	8	7	0	315	90.8
10	0	0	0	0	0	0	0	12	3	221	25	0	261	84.7
11	0	0	0	4	0	1	0	1	33	30	398	0	467	85.2
12	0	0	0	0	0	0	0	0	0	0	0	571	571	100
TPS	722	389	242	103	160	134	131	100	323	296	477	571	3648	
ÜD	93.2	88.2	99.6	88.3	96.9	73.1	96.2	73	88.5	74.7	83.4	100		

Test verisi hata matrisine göre en düşük performans gösteren sınıflar 6, 8, 10 ve 11 nolu sınıflardır. 6 nolu sınıf 7 ve 9 nolu sınıflarla, 8 nolu sınıf 4 ve 10 nolu sınıflarla, 10 nolu sınıf 8 nolu sınıfla ve 11 nolu sınıf 4 ve 10 nolu sınıflarla büyük ölçüde karışım göstermektedirler. LVQ yapısının iki boyutlu eğitim ve test verileri için %86.4 ve %82.6 GD ile ürettiği özellik uzayı karar bölgeleri Şekil 6.32’de gösterilmektedir. MO’ya göre 8 nolu sınıf oldukça küçülürken 4 nolu sınıf özellik uzayının yaklaşık yarısına karşılık gelen sağ üst bölgesini kaplamaktadır. Ayrıca 2 nolu sınıfta oldukça genişlemiştir. LVQ yapısının ürettiği karar sınırları MLP öğrenme algoritmalarının ürettiği karar sınırlarından farklı görünümde oluşmuştur. Oluşan sınırlar daha düz ve keskindir. Bunun nedeni, LVQ yapısı çıkış uzayının 0 veya 1 den oluşan ayrık bir uzay olması ve MLP öğrenme algoritmalarının sürekli bir çıkış uzayına sahip olmalarıdır. Bu işlemin test verisi hata matrisine göre yine 6, 8 ve 10 sınıflar doğruluk değerleri en düşük sınıflar olmuşlardır. 6 nolu sınıf 5, 9 ve 11 nolu sınıflarla, 8 nolu sınıf 4, 10 ve 11 nolu sınıflarla ve 10 nolu sınıf ise 8, 9 ve 11 nolu sınıflarla karışım göstermiştir.



Şekil 6.32: LVQ yapısının ürettiği karar bölgeleri.

Tablo 6.67: LVQ yapılarına ait üretici sınıflandırma doğruluk değerleri.

YAPI NO	SINIFLAR											
	1	2	3	4	5	6	7	8	9	10	11	12
1	94.0	36.5	100	65.0	95.6	68.7	0.0	79.0	73.4	17.9	91.0	100
2	93.2	92.3	99.2	84.5	95.0	28.4	93.9	64.0	73.4	71.6	85.7	100
3	93.2	88.2	99.6	88.3	96.9	73.1	96.2	73.0	88.5	74.7	83.4	100
4	92.1	91.8	92.6	94.2	95.6	78.4	98.5	68.0	94.4	76	74.2	100
5	91.0	88.9	99.2	88.3	95.6	73.9	94.7	65.0	92.0	69.9	77.1	100
6	93.5	92.5	92.6	91.3	95.6	67.9	95.4	77.0	89.8	75.0	75.1	100
7	91.7	88.9	99.2	87.4	95.6	70.9	93.1	76.0	91.0	78.0	76.3	100
8	90.0	90.2	94.2	87.4	95.6	73.9	96.9	84.0	90.4	74.7	73.6	100
9	92.8	91.0	99.6	92.2	95.6	74.6	93.9	85.0	91.3	72.3	71.7	100
10	90.3	88.7	98.8	88.3	95.6	79.1	96.9	79.0	92.9	78.0	71.1	100
11	91.7	90.2	99.2	89.3	95.6	79.9	96.2	81.0	92.3	73.6	70.4	100
12	90.7	88.4	99.2	93.2	95.6	75.4	93.9	74.0	89.5	72.6	70.2	100
13	91.4	90.2	89.7	93.2	95.0	79.9	96.2	82.0	93.8	72.3	71.7	100
14	90.6	90.0	99.2	94.2	95.0	73.9	94.7	75.0	92.6	74.0	72.1	100
15	92.0	88.9	99.6	93.2	95.0	70.9	95.4	78.0	94.1	76.0	68.1	100
16	92.1	92.0	97.5	89.3	95.0	70.9	95.4	79.0	92.3	71.3	70.6	100
17	91.6	92.8	96.3	91.3	95.0	69.4	93.9	76.0	91.6	74.0	65.8	100
18	91.8	91.0	97.5	87.4	95.0	72.4	96.9	82.0	92.9	76.7	68.1	100
19	91.0	92.3	98.8	90.3	95.6	76.9	95.4	79.0	94.1	72.6	70.4	100
20	91.3	88.9	95.9	92.2	95.6	78.4	95.4	76.0	93.2	75.0	69.0	100
21	90.9	92.8	97.1	90.3	95.6	76.1	93.9	79.0	92.3	76.4	68.3	100
22	91.0	92.5	97.9	84.5	95.0	67.9	95.4	81.0	92.6	72.0	70.0	100
23	91.7	92.5	94.6	86.4	95.0	76.9	94.7	84.0	91.3	72.0	69.0	100
24	90.7	93.1	97.5	86.4	95.0	70.9	94.7	80.0	91.3	73.6	71.9	100

LVQ 3 nolu yapının MO yöntemiyle olan çapraz sınıflandırma matrisi Tablo 6.68'de verilmektedir. MO yöntemiyle en yüksek uygunluk değerini 5 ve 12 nolu sınıflar vermiştir.

Tablo 6.68: LVQ 3 nolu yapı ve MO çapraz sınıflandırma matrisi (GU=%59.5).

		MAKSİMUM OLABİLİRLİK											
	Sınıf	1	2	3	4	5	6	7	8	9	10	11	12
	1	0.136	0.012	0.003	0	0	0	0	0.004	0	0	0	0
	2	0.004	0.112	0.018	0	0	0	0.001	0.024	0	0	0	0
	3	0.002	0.047	0.11	0	0	0	0	0.127	0	0.007	0	0
	4	0	0	0	0.005	0	0	0	0.001	0	0	0	0
	5	0	0.004	0	0	0.001	0.001	0.003	0.002	0	0	0	0
	6	0	0	0	0	0	0.005	0.001	0.002	0	0	0.002	0
	7	0	0	0	0	0	0.001	0.014	0.018	0.001	0	0	0
	8	0	0	0	0.006	0	0	0.001	0.065	0.001	0.008	0	0
	9	0	0	0	0.001	0	0.001	0.001	0.017	0.065	0.008	0.002	0
	10	0	0	0	0.004	0	0	0	0.034	0.001	0.04	0.001	0
	11	0	0	0	0.003	0	0	0	0.004	0.009	0.01	0.021	0
	12	0.001	0	0	0	0	0.002	0	0.003	0	0	0	0.021


6.7.3. RBF YSA Yapısı Uygulaması

RBF YSA yapısı uygulamasında giriş uzayı ve ara katman arasındaki bağlantı ağırlık değerleri ilk 30 epokta gerçekleştirilen kontrolsüz sınıflandırma yöntemiyle

belirlenmiştir. Ağın ara katman ve çıkış katmanı arasındaki bağlantı ağırlık değerleri EDBD geri yayılma öğrenme algoritması kullanılarak güncellenmiştir. Ara katman aktivasyon fonksiyonu Gauss ve çıkış katmanı aktivasyon fonksiyonu ise TANH olarak ayarlanmıştır. Ayrıca değiştirilmiş RBF yapısı PROTO ara katmanı için Gauss ve MLP ara katmanı ve çıkış katmanı için TANH aktivasyon fonksiyonları kullanılmıştır. MLP ara katmanı ve çıkış katmanı ağırlık değerlerinin güncellenmesi EDBD algoritmasıyla yapılmıştır. Giriş vektörlerinin ağı verilme sırası rastlantısal olarak belirlenmiştir. RBF YSA mimari yapısıyla gerçekleştirilen sınıflandırma uygulamaları sonucunda GD ölçütüne göre test verisi için en yüksek performansı sağlayan YSA yapısı 3 nolu yapı olarak belirlenmiştir (Tablo 6.69). Bu yapının eğitim süreci sırasında elde edilen GD-Epok ve MSE-Epok grafikleri Şekil 6.33'da verilmektedir. Bu yapı için elde edilen test verisi hata matrisi de Tablo 6.70'de ve diğer yapılar için test verisi üretici doğruluk değerleri Tablo 6.71'de verilmektedir.

Tablo 6.69: BRF YSA mimari yapısıyla elde edilen GD, Kappa ve MSE değerleri.

Yapı No	EĞİTİM VERİSİ			TEST VERİSİ			Epok
	GD	Kappa	MSE	GD	Kappa	MSE	
1	93.4	92.6	0.0115	87.4	85.8	0.0200	1300
2	95.1	94.5	0.0073	88.2	86.7	0.0165	3400
3	96.3	95.9	0.0056	88.4	86.9	0.0161	1700
4	96.2	95.7	0.0050	88.1	86.6	0.0165	500




Şekil 6.33: RBF YSA yapısında 3 nolu yapıda; (a) GD-Epok ve (b) MSE-Epok grafiği.

Performans eğrilerine göre test verisi GD değeri azalırken MSE değeri de azalmıştır. Bu doğru orantılı durum ağıın genelleme yeteneğinin rölatif olarak düşük olacağını göstermektedir.

Tablo 6.70: RBF 3 nolu yapının test verisi hata matrisi (GD=%88.4, Kappa=%86.9).

	Sınıf	REFERANS VERİ												TP	KD
		1	2	3	4	5	6	7	8	9	10	11	12		
SINIFLANDIRILMIŞ VERİ	1	657	8	0	0	0	0	0	0	0	0	0	0	665	98.8
	2	65	356	22	0	9	0	0	0	0	0	0	0	452	78.8
	3	0	25	220	0	0	0	0	0	0	2	0	0	247	89.1
	4	0	0	0	97	0	0	0	11	0	0	49	0	157	61.8
	5	0	0	0	0	151	0	0	0	0	0	0	0	151	100
	6	0	0	0	0	0	98	5	0	0	0	2	0	105	93.3
	7	0	0	0	0	0	8	124	0	5	0	0	0	137	90.5
	8	0	0	0	6	0	21	1	79	3	59	7	0	176	44.9
	9	0	0	0	0	0	4	1	0	299	7	12	0	323	92.6
	10	0	0	0	0	0	0	0	9	1	215	50	0	275	78.2
	11	0	0	0	0	0	3	0	1	15	13	357	0	389	91.8
	12	0	0	0	0	0	0	0	0	0	0	0	571	571	100
TP		722	389	242	103	160	134	131	100	323	296	477	571	3648	
ÜD		91	91.5	90.9	94.2	94.4	73.1	94.7	79	92.6	72.6	74.8	100		

Test verisi hata matrisine göre en düşük performans değerlerini 6, 8, 10 ve 11 nolu sınıflar vermiştir. 6 nolu sınıf 8 nolu sınıfla, 8 nolu sınıf 4 ve 10 nolu sınıflarla, 10 nolu sınıf 8 nolu sınıfla ve 11 nolu sınıf 4 ve 10 nolu sınıfla önemli ölçüde karışım göstermiştir. RBF yapısının iki boyutlu eğitim ve test verileri için %87.6 ve %83.1 GD ile ürettiği karar bölgeleri Şekil 6.34'de verilmiştir. MO yöntemine göre 8 nolu sınıf oldukça küçük bir bölgeye kapanırken 6 nolu sınıf özellik uzayının yarısından çoğuna dağılmıştır. Diğer sınıflar birleşmiş bir halde köşegen üzerinde bir dağılım göstermektedirler. 1 nolu sınıf orijine doğru basıkmıştır. Bu işlemin test verisi hata matrisine göre yine 6, 8 ve 10 nolu sınıflar en düşük performans değerini vermişlerdir. 6 nolu sınıf 5, 9 ve 11 nolu sınıflarla, 8 nolu sınıf 4, 10 ve 11 nolu sınıflarla ve 10 nolu sınıf ise 3, 8 ve 11 nolu sınıflarla karışım göstermiştir. 6 nolu sınıf bu kadar geniş yer kaplamasına karşın elde ettiği test verisi kullanıcı doğruluk değeri yüksek olmuştur.



Şekil 6.34: RBF yapısının ürettiği karar bölgeleri.

Tablo 6.71: RBF yapılarının test verisi üretici doğruluk değerleri.

SINIF	YAPI NO			
	1	2	3	4
1	91.6	89.6	91	90.6
2	91.3	90	91.5	93.3
3	98.3	100	90.9	97.1
4	88.3	94.2	94.2	89.3
5	93.1	95	94.4	93.1
6	76.1	72.4	73.1	72.4
7	96.9	96.2	94.7	94.7
8	63.0	78.0	79.0	85.0
9	90.1	91.6	92.6	91.3
10	64.2	68.9	72.6	68.2
11	73.2	74.6	74.8	72.7
12	100	100	100	100

RBF 3 nolu yapının MO yöntemiyle olan çapraz sınıflandırma matrisi Tablo 6.72’de verilmiştir. MO yöntemiyle en yüksek uygunluk değerini 5 ve 12 nolu sınıflar vermiştir. Tablo 6.73’de RBF yapılarının ve MO yönteminin genel uygunluk matrisi verilmektedir. Buna göre MO yöntemiyle en yüksek uygunluk değerini veren yapı 3 nolu yapıdır.

Tablo 6.72: RBF 3 nolu yapı ve MO çapraz sınıflandırma matrisi (GU=%65.8).

		MAKSİMUM OLABİLİRLİK											
	Sınıf	1	2	3	4	5	6	7	8	9	10	11	12
RBF	1	0.135	0.011	0.002	0	0	0	0	0.003	0	0	0	0
	2	0.007	0.129	0.023	0	0	0	0.001	0.031	0	0.001	0	0
	3	0.001	0.031	0.104	0	0	0	0	0.065	0	0.004	0	0
	4	0	0	0	0.006	0	0	0	0.001	0	0	0.001	0
	5	0.001	0.003	0	0	0.001	0.001	0.003	0.003	0	0	0	0
	6	0	0	0	0	0	0.005	0.001	0.002	0	0	0.001	0
	7	0	0	0	0	0	0.001	0.015	0.023	0.001	0	0	0
	8	0	0	0.001	0.005	0	0.001	0.001	0.105	0.003	0.011	0	0
	9	0	0	0	0	0	0	0.001	0.008	0.068	0.006	0.004	0
	10	0	0	0.001	0.004	0	0	0	0.05	0	0.049	0.003	0
	11	0	0.001	0	0.002	0	0	0	0.007	0.004	0.002	0.019	0
	12	0	0	0	0	0	0.002	0	0.003	0	0	0	0.021

Tablo 6.73: RBF yapılarının kendi içinde ve MO yöntemiyle olan uygunluk matrisi.

	MO	1	2	3	4
MO	100	60.4	64	65.8	65.3
1		100	86.5	81.6	81.6
2			100	85.2	83.8
3				100	86.8
4					100


6.7.4. Genel Karşılaştırma

Tüm YSA algoritmaları için en büyük sınıflandırma doğruluk değerini veren yapıların ürettiği GD, Kappa ve üretici doğruluk değerleri, Maksimum Olabilirlik yöntemiyle birlikte karşılaştırmalı olarak verilmektedir (Tablo 6.74).


Tablo 6.74: Bütün sınıflandırma algoritmaları için test verisi GD, Kappa ve üretici doğruluk değerleri.

	SINIFLAR													
	GD	Kappa	1	2	3	4	5	6	7	8	9	10	11	12
MO	84.9	83.0	99.7	75.1	66.3	60.6	100	67.5	83.6	37.2	90.1	82.3	96.3	100
Delta	90.0	88.7	90.4	90.5	99.2	89.3	93.1	81.3	96.9	80	92	72.6	83.2	100
DBD	91.1	90.0	91.7	92.5	93.4	74.8	94.4	85.8	95.4	84	94.1	81.4	85.5	100
EDBD	90.3	89.1	92.2	92.8	91.3	92.2	93.7	81.3	94.7	86	92.9	76.4	80.9	100
BFGS	90.5	89.3	91.1	89.5	99.2	89.3	91.9	72.4	93.9	78.0	95.7	78.4	85.3	100
EGPB	90.8	89.6	93.4	91.3	99.2	89.3	88.8	75.4	92.4	71.0	94.7	80.1	84.1	100
EGFR	90.5	89.2	91.3	90.5	98.8	80.6	93.1	73.1	93.9	76.0	94.4	80.4	85.5	100
EGPR	90.4	89.2	92.2	91.3	97.1	90.3	91.3	73.1	96.2	73.0	95.0	76.0	84.7	100
TAS	90.8	89.6	92.1	88.4	100	93.2	94.4	76.9	93.9	83.0	95.7	77.4	83.2	100
EG	91.4	90.3	94.0	92.5	99.6	93.2	90.0	86.6	96.2	71.0	92.6	81.4	81.8	100
ÖEG	90.3	89.1	91.6	89.5	100	90.3	93.1	80.6	96.9	69.0	94.4	78.0	82.0	100
LVQ	89.8	88.5	93.2	88.2	99.6	88.3	96.9	73.1	96.2	73.0	88.5	74.7	83.4	100
RBF	88.4	86.9	91.0	91.5	90.9	94.2	94.4	73.1	94.7	79.0	92.6	72.6	74.8	100

YSA uygulamaları içinde sınıflandırma performansı yönünden en optimal olan yapıların ürettiği sınıflandırılmış görüntüler Şekil 6.35 ve Şekil 6.36'de verilmektedir.



Şekil 6.35: Sınıflandırılmış görüntüler: (a) Delta, (b) DBD, (c) EDBD, (d) BFGS, (e) EGPB, (f) EGFR.



Şekil 6.36: Sınıflandırılmış görüntüler: (a) EGPR, (b) TAS, (c) EG, (d) ÖEG, (e) LVQ, (f) RBF.

6.7.5. Sürekli Eğitim

Bu bölümde BFGS-QN, EGPB, EGFR, EGPR, TAS, EG ve ÖEG algoritmalarında kesintili ve sürekli eğitimin etkisi incelenmiştir. Bu yapılar, matematiksel yapıları gereği sadece içinde bulundukları eğitim epoğunda hesaplanan gradiyenti değil bir önceki epokta hesaplanan gradiyent değerini de kullanarak oluşturdıkları performans değerine göre ağıın serbest parametrelerini güncelledikleri için eğitim sürecinin herhangi bir şekilde kesilmesi ağıın performans uzayında kazandığı trendi kaybedecek ve ağıın eğitime tekrar başlatılmasıyla farklı bir performans trendine girelecektir. Ayrıca ağ serbest parametrelerinin güncellenmesinde kullanılan diğer parametrelerin eğitim sürecinde sürekli güncellenerek elde ettikleri optimal değerleri de kaybolacaktır. Bu durumda kesintili eğitimle belirli adımlarda ağıın durdurularak tekrar eğitime başlatılmasıyla birbirinden farklı birçok ağ oluşacaktır. Bunun nedeni ise her bir istasyon noktasında yukarıda belirtilen ağ yapıları, gerekli parametrelerin başlangıçtan bir önceki epoka kadar adaptif olarak hesaplanan değerlerini kaybetmiş ve tekrar başlatıldığında sanki ağ yapısı ilk defa eğitime başlıyormuş gibi davranmasıdır.

Sürekli eğitimin kesintili eğitimle karşılaştırılabilmesi için öğrenme algoritmalarının kaynak kodları içine eklenen küçük bir alt programla ağ yapıları eğitim sürecinde durdurulmadan her bir epokta güncellenen ağ parametreleri (ağırlık ve bias) kaydedilmiştir. Kaydedilen bu değerler daha sonra oluşturulan şablon ağ yapılarına atanarak oluşturulan yapılar için kesintili eğitim uygulamalarında olduğu gibi ağ performans değerleri hem eğitim hem de test verisi için sınıflandırma genel doğruluk değerleri, Kappa değerleri ve karesel ortalama hata (MSE) değerleri hesaplanmıştır. Belirtilmesi gereken önemli diğer bir nokta da sürekli eğitim için kullanılan algoritmaların kesintili eğitimde kullanıldıklarında sahip oldukları performans uzayındaki aynı yerden başlatılmış olmalarıdır. Diğer bir ifade ile sürekli eğitimde yapıların başlangıç ağırlık ve bias değerleri kesintili eğitimdeki değerleriyle aynı olacak şekilde ayarlanmıştır. Böylece farklı başlangıç değerlerinin ağıın yakınsama performansı üzerine olabilecek etkileri ortadan kaldırılmış ve daha tutarlı bir karşılaştırma imkanı sağlanmış olmaktadır. Karşılaştırma için kullanılan ağ topolojileri kesintili eğitimde en yüksek test verisi genel sınıflandırma doğruluk değerinin elde edildiği ağ topolojileriyle belirlenmiştir. Buna göre BFGS-KN için

[12^{Giriş}⇒24^{Ara}⇒30^{Ara}⇒12^{Çıkış}], EGPB için [12^{Giriş}⇒9^{Ara}⇒15^{Ara}⇒12^{Çıkış}], EGFR için [12^{Giriş}⇒15^{Ara}⇒12^{Çıkış}] EGPR için [12^{Giriş}⇒12^{Ara}⇒24^{Ara}⇒12^{Çıkış}] TAS için [12^{Giriş}⇒12^{Ara}⇒24^{Ara}⇒12^{Çıkış}] EG için [12^{Giriş}⇒24^{Ara}⇒30^{Ara}⇒12^{Çıkış}] ve ÖEG için de [12^{Giriş}⇒24^{Ara}⇒30^{Ara}⇒12^{Çıkış}] yapıları kullanılmıştır.

Uygulama sonuçlarına göre dikkat çekicidir ki aynı ağ topolojisine sahip olmalarına ve aynı ağırlık ve bias değerleriyle performans uzayında aynı yerden başlatılmalarına rağmen sürekli eğitimde, kullanılan bütün öğrenme algoritmalarından elde edilen performans değerleri kesintili eğitim sürecinde elde edilen değerlerin altında kalmıştır (Tablo 6.75). Ayrıca bütün yapıların sürekli ve kesintili eğitimle elde ettikleri üretici doğruluk değerleri Tablo 6.76’de verilmektedir.

Tablo 6.75: MLP öğrenme algoritmalarının sürekli ve kesintili eğitim performansları.


Algoritma	KESİNTİLİ EĞİTİM				SÜREKLİ EĞİTİM			
	GD	Kappa	MSE	Epok	GD	Kappa	MSE	Epok
BFGS	90.5	89.3	0.0154	2000	90.1	88.9	0.0780	1680
EGPB	90.8	89.6	0.0142	3600	90.1	88.8	0.0145	3701
EGFR	90.5	89.2	0.0205	2500	89.1	87.6	0.0563	2382
EGPR	90.4	89.2	0.0147	4700	90.1	88.9	0.0770	6488
TAS	90.8	89.6	0.0150	9500	90.7	89.5	0.0691	7510
EG	91.4	90.3	0.0167	10900	89.4	88.0	0.0648	4909
ÖEG	90.3	89.1	0.0160	2000	89.8	88.5	0.0659	1436

Tablo 6.76: Sürekli ve kesintili eğitilen yapıların üretici doğruluk değerleri.


		Sınıflar											
		1	2	3	4	5	6	7	8	9	10	11	12
SÜREKLİ	BFGS	92.4	90.2	95.5	85.4	93.1	71.6	90.8	74.0	93.5	80.7	84.1	100
	EGPB	94.2	90.0	97.9	91.3	90.6	73.1	95.4	70.0	94.4	80.7	78.0	100
	EGFR	99.3	64.8	94.2	83.5	93.7	77.6	93.9	68.0	94.4	77.7	87.0	100
	EGPR	93.9	91.5	93.8	89.3	91.9	73.1	91.6	82.0	93.8	80.1	79.0	100
	TAS	92.4	86.9	99.6	95.1	95.0	78.4	93.1	80.0	96.0	76.7	83.2	100
	EG	93.4	86.6	93.0	90.3	93.1	75.4	95.4	70.0	93.8	72.0	83.9	100
	ÖEG	91.4	86.6	94.6	89.3	91.3	82.8	98.5	71.0	94.7	74.3	84.7	100
KESİNTİLİ	BFGS	91.1	89.5	99.2	89.3	91.9	72.4	93.9	78.0	95.7	78.4	85.3	100
	EGPB	93.4	91.3	99.2	89.3	88.8	75.4	92.4	71.0	94.7	80.1	84.1	100
	EGFR	91.3	90.5	98.8	80.6	93.1	73.1	93.9	76.0	94.4	80.4	85.5	100
	EGPR	92.2	91.3	97.1	90.3	91.3	73.1	96.2	73.0	95.0	76.0	84.7	100
	TAS	92.1	88.4	100	93.2	94.4	76.9	93.9	83.0	95.7	77.4	83.2	100
	EG	94.0	92.5	99.6	93.2	90.0	86.6	96.2	71.0	92.6	81.4	81.8	100
	ÖEG	91.6	89.5	100	90.3	93.1	80.6	96.9	69.0	94.4	78.0	82.0	100

Bu performans üstünlüğüne rağmen kesintili eğitime göre sürekli eğitimde ağına yakınsama süresi daha az olmuştur. Ayrıca karşılaştırmayı görsel olarak ortaya koymak için algoritmaların her iki eğitim şeklinde test verisi için ürettikleri


sınıflandırma genel doğruluk değerleri aşağıdaki Şekil 6.37, Şekil 6.38, Şekil 6.39, Şekil 6.41, Şekil 6.42 ve Şekil 6.43’de verilmiştir.




Şekil 6.37: BFGS öğrenme kuralı.




Şekil 6.38: EGPB öğrenme kuralı.




Şekil 6.39: EGFR öğrenme kuralı.




Şekil 6.40: EGPR öğrenme kuralı.



Şekil 6.41: TAS öğrenme kuralı.



Şekil 6.42: EG öğrenme kuralı.



Şekil 6.43: ÖEG öğrenme kuralı.

7. SONUÇLAR

Bu çalışmada, piksel tabanlı spektral sınıflandırma problemi için gerçekleştirilen uygulamalar sonucunda, bütün YSA yapılarından (MLP, LVQ, RBF) elde edilen test verisi sınıflandırma genel doğruluk (GD) ve Kappa değerlerinin, maksimum olabilirlik (MO) yönteminden 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 apriori bir 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. Ayrıca bu tez çalışmasında analiz edilen uydu görüntü verisinin sahip olduğu yüksek uzaysal frekans özelliğinin, bütün YSA sınıflandırma algoritmalarının MO sınıflandırma yönteminden daha yüksek sınıflandırma performansı elde etmelerinde etkili olduğu görülmüştür.

Maksimum Olabilirlik (MO) yönteminden elde edilen test verisi genel doğruluk değerinin YSA sınıflandırma algoritmalarından elde edilen doğruluk değerlerinden düşük olmasına karşın, her bir sınıf için elde edilen üretici doğruluk değerleri karşılaştırıldığında MO yönteminin, 1 ve 5 nolu sınıflar için bütün YSA algoritmalarından çok daha yüksek bir performansla mükemmel sonuçlar verdiği gözlenmiştir. Yine 10 ve 11 nolu sınıf performansları da YSA algoritmalarından elde edilen performans değerlerinden daha yüksek olmuştur. MO yöntemi 2, 3, 4, 6, 7, 8 ve 9 nolu sınıflar için YSA sonuçlarına göre daha düşük sonuçlar üretmiştir. Özellikle istatistiksel ayırt edilebilirlik derecesi oldukça düşük olan 8 nolu sınıf için oldukça kötü bir sınıflandırma performansı vermiştir. Bu sınıfın test verisi hata

matrisinde özellikle 10 nolu sınıfla büyük oranda karışım gösterdiği tespit edilmiştir. Hava fotoğraflarıyla yapılan arazi doğruluğunda da 8 nolu sınıfın büyük oranda 10 ve 4 nolu sınıflarla karışım gösterdiği görülmüştür. Bunu nedeni, eğitim verisi sınıf istatistikleri incelendiğinde 8 ve 10 nolu sınıf ortalama değerlerinin birbirlerine yakın olması ve 8 nolu sınıfın daha büyük bir varyans değerine sahip olmasıdır. Bu durum iki boyutlu özellik uzayında her bir sınıf için çizilen logaritmik Gauss olasılık yoğunluk fonksiyon grafiklerinde de görülmüştür.

YSA yapılarında (LVQ yapısında sadece ara katman çıkış katmanına tam bağlı değildir) işlemci elemanlar birbirlerine tümüyle bağlı oldukları için her bir sınıf karar sınırının oluşmasında bütün eğitim verisinin etkisi olmaktadır. Böylece YSA, eğitim verisini olduğundan daha fazla kullanmaktadır. Ayrıca öncül bir dağılım kabulü gerektirmeyerek doğrudan verinin kendi değerlerini kullanmaktadır.

Bu çalışmada, özellikle 12 nolu sınıf sonuçları MO ve YSA yöntemlerinin genelleme yeteneklerinin karşılaştırılması için açık bir örnek olmuştur: Çalışma görüntüsünün sağ tarafındaki Alibeyköy baraj göletinin kuzey yönündeki devamı MO sınıflandırma görüntüsünde 12 nolu sınıf yerine 8 nolu sınıfa atanırken aynı şartlar altında bütün YSA yapıları (MLP, LVQ ve RBF) bu bölgeyi doğru bir şekilde 12 nolu sınıf olarak kategorize etmiştir.

MLP YSA uygulamasında her bir öğrenme kuralı için tasarlanan bütün ağ yapılarının genel doğruluk, Kappa ve üretici doğruluk değerleri hesaplanmıştır. İlgilenilen sınıflandırma problemi için en optimal ağ yapısı sınıflandırma GD değerlerine göre belirlenmiştir. Buna göre Delta öğrenme kuralı için 4 nolu YSA yapısı, DBD öğrenme kuralı için 1 nolu YSA yapısı, EDBD öğrenme kuralı için 3 nolu YSA yapısı, BFGS öğrenme kuralı için 9 nolu YSA yapısı, EGPB öğrenme kuralı için 6 nolu YSA yapısı, EGFR öğrenme kuralı için 2 nolu YSA yapısı, EGPR öğrenme kuralı için 7 nolu YSA yapısı, TAS öğrenme kuralı için 7 nolu YSA yapısı, EG öğrenme kuralı için 9 nolu YSA yapısı ve ÖEG öğrenme kuralı için 9 nolu YSA yapısı en büyük test verisi GD değerini veren yapılar olmuşlardır. Bu yapıların verdiği doğruluk değerleri karşılaştırıldığında Esnek Geri Yayılma öğrenme algoritmasının GD değerinin en yüksek ve Delta algoritmasına ait GD değerinin en düşük doğruluk değerleri oldukları görülmüştür.

Delta algoritması maksimum sınıflandırma GD değerini tek ara katmanlı 4 nolu yapı için en düşük GD değerini de iki ara katmanlı 7 nolu yapı için vermiş olmasına rağmen, diğer Delta ağ yapıların sonuçları analiz edildiğinde ara katman ve bu katmanlarda kullanılan işlemci eleman sayılarının sınıflandırma performansına önemli bir etkisinin olmadığı görülmüştür.

DBD algoritması için iki ara katmanlı yapıların tek ara katmanlı yapılardan daha düşük sınıflandırma performansı verdikleri görülmüştür. En yüksek GD değerinin 1 nolu yapı ve en düşük GD değerinin de 9 nolu yapı için elde edilmiş olması DBD algoritmasının artan parametre sayısına bağlı olarak genelleme yeteneğini kaybettiğini göstermiştir.

EDBD algoritması da en düşük sınıflandırma GD değerini 6 ve 7 nolu iki ara katmanlı yapılar için vermiştir. 1 nolu yapı dışındaki tek ara katmanlı yapıların ürettiği doğruluk değerleri daha yüksek çıkmıştır.

BFGS algoritması ağ parametre sayısı arttıkça genelleme yeteneğini arttıran bir karakter göstermiştir. Hem tek katmanlı hem de iki katmanlı yapılarda elde ettiği GD değerleri artan işlemci eleman sayısına bağlı olarak artmıştır. 6 nolu yapı dışında diğer iki katmanlı yapılar için elde edilen GD değerleri tek katmanlı yapılardan elde edilen GD değerlerinden çok daha iyi çıkmıştır. En düşük doğruluk değeri 1 nolu yapı için elde edilmiştir.

EGPB algoritması, istisnasız bütün iki katmanlı yapılar için tek katmanlı yapılardan daha iyi bir sınıflandırma performansı sergilemiştir. Tek ara katmanlı ağlarda işlemci eleman sayısı ile birlikte artan bir sınıflandırma doğruluğuna sahip olmuştur. Elde edilen en düşük doğruluk değeri 1 nolu yapı için elde edilmiştir.

EGFR algoritması, hem tek ara katmanlı hem de iki ara katmanlı yapılarda yüksek sınıflandırma performansı vermiş olmasına rağmen iki ara katmanlı yapılar genel olarak daha yüksek sınıflandırma performansına sahip olmuştur. En düşük sınıflandırma GD değeri 1 nolu yapı için elde edilmiştir.

EGPR algoritması da açık bir şekilde iki ara katmanlı yapılarda daha yüksek sınıflandırma performansı göstermiştir. En düşük sınıflandırma GD değerinin 1 nolu

yapı için elde edildiği tek ara katmanlı yapılarda ağ genelleme yeteneğinin oldukça düştüğü gözlenmiştir.

TAS algoritmasında en düşük sınıflandırma performansı 2 nolu tek ara katmanlı yapı için elde edilmiştir. Diğer tek ara katmanlı yapıların ürettiği sınıflandırma GD değerleri iki ara katmanlı yapıların ürettiği değerlerin altında kalmıştır.

EG algoritmasında, iki ara katmanlı yapıların verdiği sınıflandırma GD değerleri önemli oranda tek ara katmanlı yapıların verdiği değerlerden daha yüksek çıkmıştır. Özellikle iki ara katmanlı yapılarda işlemci eleman sayısı arttıkça ağ genelleme yeteneği de artmıştır. En düşük sınıflandırma GD değeri 2 nolu yapı için elde edilmiştir.

ÖEG algoritmasında da hem tek ara katmanlı hem de iki ara katmanlı yapılarda işlemci eleman sayısı arttıkça ağın genelleme yeteneği artmıştır. Minimum GD değeri 1 nolu yapı için elde edilirken maksimum GD değeri 9 nolu yapı için elde edilmiştir.

Delta, DBD ve EDBD algoritmalarının çıkış katmanlarında “softmax” aktivasyon fonksiyonu kullanılmıştır. Bu aktivasyon fonksiyonu Delta, DBD ve EDBD algoritmalarında sınıflandırma performansını önemli ölçüde artırırken diğer algoritmalar için kullanımında problemler ortaya çıkmıştır. EDBD algoritması hariç diğer algoritmalar için ara katmanlarda TANH aktivasyon fonksiyonu kullanılmıştır.

MLP öğrenme algoritmaları içinde en hızlı yakınsayan algoritma Delta olurken en yavaş yakınsayan algoritma Tek Adım Sekant olmuştur. YSA MLP yapıları içinde Delta, DBD ve EDBD algoritmaları, Kuasi-Newton, Eşleştirmeli Gradyent, Ölçeklendirilmiş Eşleştirmeli Gradyent ve ve Esnek geri yayılma öğrenme algoritmalarından işlemsel olarak daha hızlıdır. İkinci dereceden nümerik optimizasyon tekniklerine dayanan öğrenme algoritmaları içinde işlemsel hız gereksinimi yönünden ÖEG algoritmasının en hızlı öğrenme algoritması olduğu gözlenmiştir. Özellikle BFGS algoritmasının diğer algoritmalara göre oldukça yavaş bir işlemsel hıza sahip olduğu gözlenmiştir. Sınıflandırma performans üstünlüğüne rağmen MO yöntemi bütün YSA sınıflandırma algoritmalarından daha az işlemsel zaman gerektirmiştir. YSA algoritmalarının yüksek işlemsel zaman gereksinimi en büyük dezavantajları olmuştur.

Görüntünün iki boyutlu özellik uzayı için gerçekleştirilen uygulamalarda ortaya çıkan sonuçlar Delta, DBD ve EDBD algoritmalarının özellik uzayını kategorize etme davranışlarının birbirine benzemesine rağmen diğer algoritmaların büyük farklılıklar ortaya koyduklarını göstermiştir. İki boyutlu özellik uzayı üzerinde görülen sınıflandırma özelliklerinin bu işlemin 6 boyutlu eşleniği olan 6 kanallı tüm görüntü için yapıldığında elde edilen sonuçların birbirine paralel oldukları görülmüştür. Bu açıdan özellik uzaylarının incelenmesinin sınıflandırma algoritmasının ve her bir sınıfın sahip olduğu karakteristik özelliklerinin görüntülenmesi açısından katkıları vardır. Arazi doğruluklarını analiz edebilmek için elde edilen sonuç sınıflandırma görüntüleri mevcut 1/5000 ölçekli fotogrametrik hava fotoğraflarıyla karşılaştırılmıştır. Test verisi için bütün MLP öğrenme algoritmalarında düşük sınıflandırma performansı gösteren 6, 8, 10 ve 11 nolu sınıfların görüntü üzerinde de başka sınıflarla karışım gösterdikleri gözlenmiştir. 6 nolu sınıfın 7 nolu sınıfla, 8 nolu sınıfın 3 ve 4 nolu sınıflarla, 10 nolu sınıfın 8 nolu sınıfla ve 11 nolu sınıfında 9 nolu sınıfla karışım gösterdiği gözlenmiştir. Ayırt edilebilirlik analizlerinde de özellikle 8 ve 10 nolu sınıfların ayırt edilebilirlik derecelerinin çok düşük olduğu gözlenmiştir.

LVQ YSA yapısı uygulamasında KOHONEN ara katmanında her bir sınıf için kullanılan referans vektörü sayısı değiştirilerek farklı işlemci eleman sayısı elde edilmiştir. Sonuçta oluşturulan 24 farklı LVQ ağ yapısından 3 nolu yapının en yüksek sınıflandırma GD değerini verdiği belirlenmiştir. 3 nolu yapı, her bir sınıf için 3 referans vektörü ve dolayısıyla toplamda KOHONEN ara katmanı için 36 işlemci eleman içeren bir yapıdır. LVQ YSA yapısının maksimum sınıflandırma performansı, bütün MLP yapılarından elde edilen maksimum sınıflandırma performans değerlerinin altında kalmıştır. LVQ YSA yapısının ürettiği iki boyutlu özellik uzayındaki karar bölgeleri bu yapının çıkış uzayının sadece 0 ve 1 olmak üzere iki elemandan oluştuğunu grafik olarak göstermektedir. LVQ karar bölgeleri, çıkış uzayları 0 ve 1 arasında sürekli değerlerden oluşan MLP karar bölgeleriyle karşılaştırıldığında çıkış uzayları arasındaki farklılık açıkça görülebilmektedir. LVQ çıkış uzayının bu özelliğinden dolayı ara katman işlemci eleman sayılarına göre olan ağ eğitim performans grafiklerinde sınıflandırma GD değeriyle MSE değerinin tamamen ters orantılı oldukları görülmektedir. Yani GD değeri artıyorsa MSE değeri kesinlikle azalıyor ve azalıyorsa kesinlikle artıyor. MLP YSA yapısında olduğu gibi

LVQ sınıflandırma sonuçlarının hava fotoğraflarıyla karşılaştırılması sonucunda performans değerlerine paralel olarak 6,8 ve 10 nolu sınıfların daha fazla karışım gösterdikleri gözlenmiştir. Bu sınıflardan 6 nolu sınıf 7 ve 9 nolu sınıflarla, 8 nolu sınıf 4 ve 10 nolu sınıflarla ve 10 nolu sınıfta 8 ve 11 nolu sınıflarla karışım göstermiştir.

RBF YSA yapısı uygulamasında maksimum sınıflandırma performans değerini üreten yapı 3 nolu yapı olmuştur. RBF YSA yapısı da MO yönteminden daha üstün bir sınıflandırma performansı göstermesine karşın MLP ve LVQ YSA yapılarının altında kalmıştır. Standart RBF yapısına ek olarak MLP karakterli ikinci bir ara katmanın kullanıldığı değiştirilmiş RBF yapısının sınıflandırma performansı, aynı sayıda PROTO ara katmanı işlemci elemanı kullanan standart 1 nolu RBF yapısından daha yüksek çıkmıştır. Ayrıca bütün RBF uygulamalarında yakınsama hızı en iyi olan yapı olmuştur. RBF YSA yapılarında, çıkış katmanı aktivasyon fonksiyonu olarak “softmax” iyi sonuçlar vermemiştir. RBF YSA yapısının ürettiği iki boyutlu özellik uzayı karar bölgeleri MLP yapısının ürettiği karar bölgelerine benzemektedir. RBF yapılarının da çıkış uzayı 0 ve 1 arasında sürekli bir uzaydır. RBF sınıflandırma sonuçlarının hava fotoğraflarıyla karşılaştırılmasıyla 6 nolu sınıfın 8 ve 4, 8 nolu sınıfın 10 ve 8, 10 nolu sınıfın 11 ve 4, 11 nolu sınıfın da 10 nolu sınıflarla karışıkları gözlenmiştir.

MO yönteminin bütün YSA yapılarıyla hesaplanan çapraz sınıflandırma matrislerine göre en büyük uygunluk değerini veren YSA algoritması %68.7 değeriyle DBD algoritması olmuştur. Yine MO yöntemi sınıflandırma görüntüsüyle en düşük uygunluk değerini veren algoritma %59.1 değeriyle EGFR algoritması olmuştur. Bu analizler sonucunda MO yöntemiyle bütün YSA yapıları arasında en büyük uygunluk değerinin elde edildiği sınıflar 5 ve 12 nolu sınıflar olurken en az uygunluğun olduğu sınıfın ise 8 nolu sınıf olduğu belirlenmiştir.

Uygulamada son olarak sürekli ve kesintili eğitimlerin farkları incelenmiştir. Bu amaçla MLP öğrenme algoritmalarından BFGS, EGPB, EGFR, EGPR, TAS, EG ve ÖEG öğrenme algoritmaları kullanılmıştır. Bu algoritmaların aynı başlangıç değerleriyle (performans yüzeyinin aynı noktasından) başlatılmalarına rağmen kesintili eğitim tekniği, sürekli eğitime göre daha üstün bir sınıflandırma performansı ortaya koymuştur. Bu sonuçlar, bu öğrenme algoritmalarında, ağız eğitimi süresince

güncellenen parametrelerin belirli adımlarda tekrar ayarlanması bu tip bir sınıflandırma uygulamasında olumlu etkisinin olduğunu deneysel olarak ortaya koymaktadır. Bu performans üstünlüğüne rağmen sürekli eğitimin yakınsama hızı kesintili eğitime göre daha yüksektir.

Bu uygulamalar ışığında genel olarak, MLP YSA yapılarında incelenen sınıflandırma problemi için Delta, DBD ve EDBD algoritmalarında tek ara katmanlı ve ara katmanında 18 işlemci elemanın bulunduğu 3 nolu yapı ve BFGS, EGPB, EGFR, EGPR, TAS, EG ve ÖEG öğrenme algoritmaları için ise iki ara katmanlı ve birinci ara katmanında 24, ikinci ara katmanında 30 işlemci eleman bulunduran 9 nolu yapı optimum bulunmuştur. Ayrıca MLP öğrenme algoritmaları içinde performans değeri, yakınsama ve işlem hızı dikkate alındığında Esnek Geri Yayılma algoritmasının ilgilenilen sınıflandırma problemi için en optimal algoritma olduğu görülmüştür.

Elde edilen maksimum sınıflandırma performanslarına göre YSA yapıları MLP, LVQ ve RBF olarak sıralanmıştır. Genel olarak yakınsama hızına göre LVQ, MLP ve RBF olarak sıralanmışlardır. Özellikle LVQ YSA yapısının yakınsama hızının MLP ve RBF yapılarıyla karşılaştırıldığında oldukça düşük olduğu görülmüştür.

Ayrıca, bütün MLP ve RBF YSA uygulamaları için optimum ağ yapısının belirlenmesinde tek başına MSE ölçütünün yeterli olmadığı görülmüştür. Bazı öğrenme algoritmalarında MSE değeri düşmesine rağmen sınıflandırma genel doğruluk değeri artmamıştır. Bu sonuç, sınıflandırma performansı yönünden optimum ağ yapısının seçilmesinde MSE performans değeri yerine sınıflandırma genel doğruluk değerinin kullanılmasının gerekliliğini göstermiştir. Ayrıca LVQ YSA yapısı için optimum ağ yapısına karar verilmesinde MSE değerinin kullanılmasında hiç bir sakınca olmadığı görülmüştür. Elde edilen sonuçlar bütün LVQ ağ yapıları için MSE ve sınıflandırma genel doğruluk değerleri arasında tam bir uygunluk olduğunu göstermiştir. Bunun nedeni, LVQ YSA yapısının çıkış uzayının ayrık kesin değerlerden oluşmasına rağmen MLP ve RBF YSA yapılarının çıkış uzayları süreklilik gösteren bir yapıda olmasıdır.

Bu çalışmada gerçekleştirilen uygulamalar, YSA sınıflandırma algoritmalarının çok spektrumlu uydu görüntü verilerinin sınıflandırılması için klasik yöntemlerle kıyaslanabilir ve hatta daha iyi performans gösteren etkin sınıflandırma araçları

olduklarını göstermiştir. YSA'nın en büyük dezavantajı olan işlemsel zaman gereksinimi daha hızlı bilgisayar donanım ve algoritmalarının geliştirilmesiyle aşılabilecektir. YSA'nın en belirgin avantajlarından biri olan bütünüyle paralel çalışabilme özelliği donanım olarak gerçekleştirilebildiği ölçüde işlem hızının artacağı açıktır.



KAYNAKLAR

- [1] Örmeci, C., 1987. Uzaktan Algılama: Temel Esaslar ve Algılama Sistemleri, İTÜ Matbaası, Cilt I.
- [2] Shavlik, J.W., Mooney, R.J. and Towell, G.G., 1991. Symbolic and Neural Learning Algorithms: An Experimental Comparison, *Machine Learning*, 6, 111-143.
- [3] Drago, G.P. and Ridella, S., 1992. Statistically Controlled Activation Weight Initialization (SCWAI), *IEEE Transactions on Neural Networks*, July, 3, 627-631.
- [4] Warner, T. and Shank, M., 1997. An Evaluation of the Potential for Fuzzy Classification of Multispectral Data Using Artificial Neural Networks, *Photogrammetric Engineering & Remote Sensing*, November, 63, 1285-1294.
- [5] Baraldi, A. and Parmiggiani, F., 1995. A Neural Network for Unsupervised Categorization of Multivalued Input Patterns: An Application to satellite Image Clustering, *IEEE Transactions on Geoscience and Remote Sensing*, 33, March.
- [6] Carpenter, G.A. and Grossberg, S., 1987. A Massively Parallel Architecture for a Self-Organizing Neural Pattern Recognition Machine, *Computer Vision Graphics Image Processing*, 37, 54-115.
- [7] Shih, F.Y., Moh, J. and Chang, F., 1992. A New Art-Based Neural Architecture for Pattern Classification and Image Enhancement without Prior Knowledge, *Pattern Recognition*, 25, 533-542.
- [8] Beşdok, E., 2000. Raster Veritabanlarının YSA ile Analizi, *Doktora Tezi*, İTÜ Fen Bilimleri Enstitüsü.
- [9] Bebis, G.N. and Papadourakis, G.M., 1992. Object Recognition Using Invariant Object Boundary Representations and Neural Network Models, *Pattern Recognition*, 25, 25-44.
- [10] Lin, W., Tsao, E.C. and Chen, C., 1992. Constraint Satisfaction Neural Networks for Image Segmentation, *Pattern Recognition*, 25, 679-693.
- [11] Benedictsson, J.A., Swain, P.H. and Ersoy, O.K., 1993. Conjugate-gradient Neural Networks in Classification of Multisource and Very-High

Dimensional Remote Sensing Data, *International Journal of Remote Sensing*, **14**, 2883-2903.

- [12] **Schalkoff, R.**, 1992. Pattern Recognition: Statistical Structural and Neural Approaches, New York Wiley.
- [13] **Yhann, S.R. and Simpson, J.J.**, 1995. Application of Neural Networks to AVHRR Cloud Segmentation, *IEEE Transactions on Geoscience and Remote Sensing*, May, **33**, 590-604.
- [14] **Atkinson, P.M. and Tatnall, A.R.L.**, 1997. Introduction-Neural Networks in Remote Sensing, *International Journal Remote Sensing*, **18**, 699-709.
- [15] **Benedictsson, J.A., Swain, P.H. and Ersoy, O.K.**, 1990. Neural Network Approaches Versus Statistical Methods In Classification of Multisource Remote Sensing Data, *IEEE Transactions on Geoscience and Remote Sensing*, July, **28**, 540-551.
- [16] **Benediktsson, J.A. and Sveinsson, J.R.**, 1997. Multisource Data Classification and Feature Extraction with Neural Networks, *International Journal of Remote Sensing*, **18**, 727-740.
- [17] **Yoshida, T., Omatu, S. and Teranisi, M.**, 1991. Pattern Classification for Remote Sensing Data Using Neural Network, *Trans. Inst. Syst. Cont. Inform. Eng.*, **4**, 11-20.
- [18] **Heerman, P.D. and Khazenie, N.**, 1992. Classification of Multispectral Remote Sensing Data Using A Backpropagation Neural Network, *IEEE Transactions on Geoscience and Remote Sensing*, Jan., **30**, 81-88.
- [19] **Kanellopoulos, I., Varfis, A., Wilkinson, G.G. and Megier, J.**, 1992. Land Cover Classification in SPOT HRV Imagery Using an Artificial Neural Network- A 20 Class Experiment, *International Journal of Remote Sensing*, **13**, 917-924.
- [20] **Zhuang, X., Engel, B.A., Baumgardner, M.F. and Swain, P.H.**, 1991. Improving Classification of Crop Residues Using Digital Land Ownership Data and LANDSAT TM Imagery, *Photogrammetric Engineering and Remote Sensing*, **57**, 1487-1492.
- [21] **Paola, J.D. and Schowengerdt, R.**, 1997. The Effect of Neural Network Structure on a Multispectral Land Use/Land Cover Classification, *Photogrammetric Engineering & Remote Sensing*, May, **63**, 535-544.
- [22] **Bischof, H. and Leonardis, A.**, 1998. Finding Optimal Neural Networks for Land Use Classification, *IEEE Transactions on Geoscience and Remote Sensing*, January, **36**, 337-341.
- [23] **Curran, P.J.**, 1985. Principles of Remote Sensing, New York: Longman.

- [24] Maktav, D. ve Sunar, F., 1991. Uzaktan Algılama: Kantitatif Yaklaşım, Çeviri, "SWAIN, P. H., DAVIS, S. M., 1978. *Remote Sensing: Quantitative Approach*, New York, McGraw Hill", Hürriyet Offset.
- [25] Richmond, J.C., Ginsberg, I.W., Limperis, T. and Nicodemus, F.W., 1973. Geometrical Considerations for Reflectance Nomenclature, *National Bureau of Standards*, Draft Copy.
- [26] Curlander, C.J. and McDonough, R.N., 1991. Synthetic Aperture Radar-Symtems and Signal Processing, New York, John Wiley & Sons.
- [27] Elachi, C., 1988. Spaceborne Radar Remote Sensing: Applications and Techniques, New York, IEEE Press.
- [28] Hollinger, J.P., Peirce, J.L. and Poe, G.A., 1990. SSM/I Instrument Evaluation, *IEEE Transactions on Geoscience and Remote Sensing*, **28**, 781-790.
- [29] Proy, C., Tanre, D. and Deschamps, P.Y., 1989. Evaluation of Topographic Effects in Remotely Sensed Data, *Remote Sensing of Environment*, **30**, 21-32.
- [30] Schowengerdt, R.A., 1997. Remote Sensing: Models and Methods for Image Processing, Academic Press, San Diego.
- [31] Gao, B.C., Goetz, A.F.H. and Wiscombe, W.J., 1993. Cirrus Cloud Detection from Airborne Imaging Spectrometer Data Using 1.38 μm Water Vapor Band, *Geophysical Research Letter*, **20**, 301-304.
- [32] Slater, P.N., 1980. Remote Sensing: Optics and Optical Systems, Addison-Wesley.
- [33] Berk, A., Bernstein, L.S. and Robertson, D.C., 1989. MODTRAN: A Moderate Resolution Model for LOWTRAN 7, *U.S. Air Force Geophysics Laboratory*, No. GL-TR-89-0122.
- [34] Gausman, H.W., 1977. Reflectance of Leaf Components, *Remote Sensing of Environment*, **6**, 1-9.
- [35] Moss, R.A., 1951, Absorption Spectra of Leaves, *Ph.D. Thesis*, Iowa: Iowa Sate University.
- [36] Pearman, G.I., 1966. The Reflection Of Visible Radiation From Leaves Of Some Western Australian Species, *Australian Journal Biological Science*, **19**, 97-103.
- [37] Woolley, J.T., 1971. Reflectance and Transmittance of Light by Leaves, *Plant Physiology*, **47**, 656-662.

- [38] **Memorrow, J.**, 1999. Empirical and Theoretical Relationships Between Oil Palm Plantation Age, Density and Radiance, *Symposium of RSS99*, 145-150.
- [39] **Geiger, R.**, 1965. The Climate Near The Ground, Harvard University Press, Cambridge MA.
- [40] **Bowers, S.A. and Hanks, R.J.**, 1965. Reflection Of Radiant Energy From Soils, *Soil Science*, **100**, 130-138.
- [41] **Bowers, S.A. and Smith, S.J.**, 1972. Spectrophotometric Determination Of Soil Water Content, *Soil Science Society America Proceedings*, **36**, 978-980.
- [42] **Baumgardner, M.F., Kristof, S.J., Johannsen, D.J. and Zachary, A.L.**, 1970. Effect Of Organic Matter On The Multi-Spectral Properties Of Soils, *Proceedings, Indiana Academy Of Sciences*, **79**, 413-422.
- [43] **Peterson, J.B., Robinson, B.F. and Beck, R.H.**, 1979. Predictability Of Change In Soil Reflectance On Wetting, *Proceedings Symposium Machine Processing Of Remotely Sensed Data*, West Lafayette, Indiana: Purdue University, 264-274.
- [44] **Shields, J.A., Paul, E.A., Amaud, R.J.St. and Head, W.K.**, 1968. Spectrophotometric Measurement Of Soil Color And Its Relationship To Moisture And Organic Matter, *Canadian Journal Soil Science*, **48**, 271-280.
- [45] **Stoner, E.R. and Baumgardner, M.F.**, 1980. Physicochemical Site And Bidirectional Reflectance Factor Characteristics Of Uniformly Moist Soils, LARS Technical Report 111679, West Lafayette, Indiana: Laboratory For Applications Of Remote Sensing, Purdue University.
- [46] **Stoner, E.R. and Baumgardner, M.F.**, 1981. Characteristic Variations in Reflectance of Surface Soils, *Soil Science Society, America Journal*, **45**, 1161-1165.
- [47] **Obukhov, A.I. and Orlov, D.S.**, 1964. Spectral Reflectivity of The Major Soil Groups and Possibility of Using Diffuse Reflection in Soil Investigations, *Soviet Soil Science*, **2**, 174-184.
- [48] http://foliage.geo.msu.edu/research/teaching/Geo324/Physical_Basis.pdf.
- [49] **Markham, B.L. and Townshend, J.R.C.**, 1981. Land Cover Classification Accuracy as a Function of Sensor Spatial Resolution, *Proceedings of the 15th International Symposium on Remote Sensing of Environment*, Ann Arbor, 1075-1090.
- [50] **Lintz, J. and Simonett, D.S.**, 1976. Remote Sensing of the Environment. Addison-Wesley, Reading, Massachusetts.

- [51] **American Society of Photogrammetry**, 1983. Manual of Remote Sensing, 2nd ed., Falls Church, Va.
- [52] **Townshend, J.R. and Justice, O.**, 1980. Remote Sensing for Resources, London: Allan and Unwin.
- [53] **Dereniak, E.L. and Boreman, G.D.**, 1996. Infrared Detectors and Dystems, New York: John Wiley & Sons.
- [54] **Budge, T.A.**, 1988. Directory of Major Sensors and Their Parameters, Albuquerque, New Mexico: *Technology Application Center*, University of New Mexico.
- [55] **Sonka, M., Hlavac, V. and Boyle, R.**, 1999. Image Processing Analysis and Machine Vision, 2nd ed., PWS-Brooks/Cole Publishing.
- [56] **Hardin, B.J. and Thomson, C.N.**, 1992. Fast Nearest Neighbour Classification Methods for Multispectral Imagery, *Professional Geographer*, **44**, 191-201.
- [57] **Wang, F.**, 1990. Improving Remote Sensing Image Analysis Through Fuzzy Information Representation, *Photogrammetric Engineering & Remote Sensing*, **56**, 1163-1169.
- [58] **Hepner, G.F., Logan, T., Ritter, N. and Bryant, N.**, 1990. artificial Neural Network Classification Using a Minimal Trainig Set: Comparision to Conventional Supervised Classification, *Photogrammetric Engineering and Remote Sensing*, **56**, 469,-473.
- [59] **Lillesand, M.T. and Ralph, W.K.**, 1987. Remote Sensing and Image Interpretation, New York:John Wiley & Sons.
- [60] **Stephen, P.B.**, 1991. Signal Processing, Image Processing, and Pattern Recognition, Prentice Hall (UK) Ltd.
- [61] **Schenk, T.**, 1999. Digital Photogrammetry, Terra Science, I.
- [62] **Umbaugh S.E.**, 1998. Computer Vision and Image Processing., Prentice-Hall International Inc., ISBN 0 13 790882 2, USA.
- [63] **Richards, J.A.**, 1986. Remote Sensing Digital Image Analysis-An introduction, Berlin: Springer-Verlag.
- [64] **Castleman, K.R.**, 1996. Digital Image Processing, Englewood Cliffs, NJ: Prentice Hall.
- [65] **Larsen, R.J. and Morris, L.M.**, 1981. An Introduction to Mathematical Statistics and Its Applications, Englewood Cliffs, New Jersey: Prentice Hall.

- [66] **Press, W.H., Flannery, B.P., Teukolsky, S.A. and Vetterling, W.T.**, 1986. Numerical Recipes-The Art of Scientific Computing, 1st ed., Cambridge University Press.
- [67] **Johnston, R.C.**, 1980. Multivariate Statistical Analysis in Geography, Essex, England: Longman Group Ltd.
- [68] **Christopher, C. and Alexander, J.C.**, 1992. Introduction to Multivariate Analysis, Chapman & Hall, London.
- [69] **Erdas Inc.**, 1999. Erdas Field GuideTM, 5th ed.
- [70] **Lillesand, M.T. and Ralph, W.K.**, 1999. Remote Sensing and Image Interpretation, New York: John Wiley & Sons.
- [71] **Jensen, J.R.**, 1996. Introductory Digital Image Processing: A Remote Sensing Perspective, Prentice Hall, New Jersey.
- [72] **Mather, P.M.**, 1999. Computer Processing of Remotely Sensed Images: An Introduction, Chichester: Wiley.
- [73] **Spanner, M.A., Brass, J.A. and Peterson, D.L.**, 1984. Feature Selection And The Information Content Of Thematic Mapper Simulator Data For Forest Structural Assessment, *IEEE Transactions on Geoscience and Remote Sensing*, **22**, 482-489.
- [74] **Swain, P.H. and King, R.C.**, 1973. Two Effective Selection Criteria For Multispectral Remote Sensing, *Proceedings of the 1st International Joint Conference on Pattern Recognition*, New York: IEEE Press, 536-540.
- [75] **Singh, A.**, 1984. Some Classifications About The Pairwise Divergence Method in Remote Sensing, *International Journal of Remote Sensing*, **5**, 623-627.
- [76] **Haralick, R.M. and Fu, K.S.**, 1983. Pattern Recognition and Classification, in *Manuel of Remote Sensing* (2nd R.N. Colwell ed.), Ame. Soc. Photogramm., Falls Church, VA, **2**, 793-806.
- [77] **Jensen, J.R. and Toll, D.R.**, 1982. Detecting Residential Land-Use Development at The Urban Fringe, *Photogrammetric Engineering and Remote Sensing*, **48**, 629-643.
- [78] **Jain, A.K.**, 1986. Fundamentals of Digital Image Processing, Englewood Cliffs, NJ: Prentice Hall.
- [79] **Dobbertin, M. and Biging, G.S.**, 1996. A Simulaton Study of The Effect Scene Autocorrelation, Trainig Size and The Sampling Method on Classification Accuracy, *Canadian Journal of Remote Sensing*, **22**, 360-367.

- [80] **Blamire, P.A.**, 1996. The Influence of Relative Sample Size in Training Artificial Neural Network, *International Journal of Remote Sensing*, **17**, 223-230.
- [81] **Foody, G.M., Mccullagh, M.B. and Yates, W.B.**, 1995. The Effect of Training Set Size and Composition on Artificial Neural Net Classification, *International Journal of Remote Sensing*, **16**, 1707-1723.
- [82] **Skidmore, A.K.**, 1989. Unsupervised Trainig Area Selection in Forests Using a Nonparametric Distance Measure and Spatial Information, *International Journal of Remote Sensing*, **10**, 133-146.
- [83] **Campbell, J.B.**, 1981. Spatial Correlation Effects Upon Accuracy of Supervised Classification of Land Cover, *Photogrammetric Engineering and Remote Sensing*, **47**, 355-357.
- [84] **Labovitz, M.L. and Masuoka, E.J.**, 1984. Influence of Autocorrelation in Signature Extraction—An Example from a Geobotanical Investigation of Cotter Basin, Montana, *International Journal of Remote Sensing*, **5**, 315-332.
- [85] **Foody, G.M., Campbell, N.A., Trood, N.M. and Wood, T.F.**, 1992. Derivation and Application of Probabilistic Measures of Class Membership From The Maximum Likelihood Classification, *Photogrammetric Engineering and Remote Sensing*, **59**, 1335-1341.
- [86] **Blaisdell, E.A.**, 1993. *Statistics in Practice*, New York: Harcourt Brace Javanovich.
- [87] **Gonzales, R.C. and Woods, R.E.**, 1992. *Digital Image Processing*, Addison-Wesley.
- [88] **Duda, R.D. and Hart, P.E.**, 1973. *Pattern Classification and Scene Analysis*, John Walley & Sons, New York.
- [89] **Congalton, R.G. and Green, K.**, 1999. *Assessing The Accuracy Of Remotely Sensed Data: Principles And Practices*, Lewis Publishers.
- [90] **Fitzgerald, R.W. and Lees, B.G.**, 1994. Assessing The Classification Accuracy Of Multisource Remote Sensing Data, *Remote Sensing of the Environment*, **47**, 362-368.
- [91] **Bishop, Y., Fienberg, S. and Holland, P.**, 1975. *Discrete Multivariate Analysis: Theory and Practice*, MIT Press, Cambridge, MA.
- [92] **Verbyla, D.L.**, 1995. *Satellite Remote Sensing of Naturel Resources*, Lewis Publishers.

- [93] Congalton, R.G., 1991. A Review Of Assessing The Accuracy Of Classifications Of Remotely Sensed Data, *Remote Sensing of Environment*, **37**, 35-46.
- [94] Dönmez, K., Yapay Sinir Ağları, *M.S.B. Arge Bülteni*, Sayı 3.
- [95] Mcculloch, W. and Pitts, W., 1943. A Logical Calculus Of The Ideas Immanent In Nervous Activity, *Bulletin Of Mathematical Biophysics*, **5**, 115-133.
- [96] Hebb, D.O., 1949. The Organization of Behaivour, New York:Wiley.
- [97] Rosenblatt, F., 1958. The Perseptron: A Probabilistic Model for Information Storage and Organition in The Brain, *Phychological Review*, **65**, 386-408.
- [98] Widrow, B. and Hoff, M.E., 1960. Adaptive Switcing Circuits, *IRE WESCON Convention Record*, Newyork: IRE Part 4, 96-104.
- [99] Minsky, M. and Papert, S., 1969. Perseptrons, Cambridge, MA:MIT Press.
- [100] Kohonen, T., 1972. Correlation Matrix Memories, *IEEE Transactions on Computers*, **21**, 353-359.
- [101] Anderson, J.A., 1972. A Simple Neural Network Generating An Interactive Memory, *Mathematical Biosciences*, **14**, 197-220.
- [102] Grossberg, S., 1976. Adaptive Pattern Classification and Universal Recording: I. Parallel Devolepment and Coding of Neural Feature Detectors, *Biological Cybernetics*, **23**, 121-134.
- [103] Hopfield, J.J., 1982. Neural Networks and Physical Systems with Emergent Collective Computational Abilities, *Proceedings of The National Academy of Sciences*, **79**, 2554-2558.
- [104] Orr, M.J.L., 1996. Introduction to Radial Basis Function Networks, April, <http://www.anc.ed.ac.uk/~mjopapers/intro.ps>
- [105] Darpa Neural Network Study, 1988. AFCEA International Press.
- [106] Haykin, S., 1994. Neural Networks: A Comprehensive Foundation. NY: Mcmillan Press.
- [107] Nigrin, A., 1993. Introduction to Artificial Neural Systems, Boston: PWS Publishing Company.
- [108] Simpson, P.S., 1990. Artificial Neural Networks: A Foundation, Paradigm, Applications and Implementation, Pergamon Press.

- [109] **Erler, M.**, 1999. Dikdörtgen Mikroşerit Antenlerin Yapay Sinir Ağları İle Analizi ve Tasarımı, *Doktora Tezi*, Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Kayseri.
- [110] **Hagan, M.T., Demuth, H.B. and Beale, M.**, 1996. Neural Network Design, Boston PWS Publishing Company.
- [111] **Jordan, M.I.**, 1995, Why the Logistic Fuction? A Tutorial Discussion on Probabilities and Neural Networks,
<ftp://psyche.mit.edu/pub/jordan/uai.ps.Z>
- [112] **Bridle, J.S.**, 1990. Probabilistic Interpretation of Feedforward Classification Network Outputs With Relationships to Statistical Pattern Recognition, *Neurocomputing: Algorithms, Architectures and Applications*, Berlin, Springer-Verlag.
- [113] **Mccullagh, P. and NELDER, J.A.**, Generalized Linear Models. 2nd ed., London Chapman & Hall.
- [114] **Pham, D.T. and Xing, L.**, 1995. Neural Networks For Identification Prediction and Control, Springer-Verlag, London Limited.
- [115] **Kohonen, T.**, 1989. Self Organizing and Associative Memory, 3rd ed., Berlin, Springer-Verlag.
- [116] **Albus, J.S.**, 1975. Mechanisms of Planning and Problem Solving in The Brain, *Mathematical Bioscience*, **45**, 247-293.
- [117] **Hecht-Nielsen, R.**, 1990. Neurocomputing, Reading, MA:Addison-Wesley.
- [118] **Neuralware Handbook**, 1996. Neural Computing: A Technology Handbook for Professional II/PLUS and NeuralWorks Explorer, Pittsburgh. USA.
- [119] **Elman, J.L.**, 1990. Finding Structure in Time, *Cognitive Science*, **14**, 179-211.
- [120] **Oh, S.H.**, 1997. Improving the Error Backpropagation Algorithm with a Modified Error Function, *IEEE Transactions on Neural Network*, **8**, 799-802.
- [121] **Carpenter, G.A. and Grossberg, S.**, 1988. The ART of Adaptive Pattern Recognition by a Self-Organising Neural Network, *IEEE Computer*, 77-88
- [122] **Grefenstette, J.J.**, 1986. Optimisation of Control Parameters for Genetic Algorithms, *IEEE Transactions on Systems, Man and Cybernetics*, **16**, 122-128.
- [123] **Goldberg, D.E.**, 1989. Genetic Algorithms in Search, Optimisation and Machine Learning, Addison-Wesley, Reading, MA.

- [124] **Mirchandani, G. and Cao, W.**, 1989. On Hidden Nodes for Neural Nets, *IEEE Transactions on Circuits and Systems*, **36**, 661-664.
- [125] **Chester, D.L.**, 1990. Why Two Hidden Layers Are Better Than One, *International Joint Conference on Neural Networks*, Washington, DC., **1**, 265-268.
- [126] **Riedmiller, M.**, 1994. Advanced Supervised Learning in Multi Layer Perceptrons from Backpropagation to Adaptive Learning Algorithms, *International Journal of Computer Standards and Interfaces*, Special Issue on Neural Networks, **5**.
- [127] **Caudill, M.**, 1988. Neural Networks Primer, *AI Expert*, **3**, 55-61.
- [128] **Minai, A.A. and Williams, R.D.**, 1990. Acceleration of Backpropagation Through Learning Rate and Momentum Adaptation, *International Joint Conference on Neural Networks*, **1**, 676-679.
- [129] **Jacobs, R.A.**, 1988. Increased Rate of Convergence Through Learning Rate Adaptation, *Neural Networks*, **1**, 295-307.
- [130] **Kesten, H.**, 1958. Accelerated Stochastic Approximation, *Annals of Mathematical Statistics*, **29**, 41-59.
- [131] **Saridis, G.N.**, 1970. Learning Applied to Successive Approximation Algorithms, *IEEE Transactions on Systems Science and Cybernetics*, **6**, 97-103.
- [132] **Riedmiller, M. and Braun, H.**, 1993. A Direct Adaptive Method for Faster Backpropagation Learning: The RPROP Algorithm, *Proceedings of the IEEE International Conference on Neural Networks*, San Francisco, CA, March, **1**, 586-591.
- [133] **Anderson, C.**, 1986. Learning and Problem Solving with Multilayer Connectionist Systems, *Technical Report COINS TR 86-50*, University of Massachusetts, Amherst, MA.
- [134] **Mathworks Inc.**, 1998. Matlab Neural Network Toolbox, Users Guide, 5. Printing, Version 3, Mathworks Inc.
- [135] **Bishop, C.M.**, 1995. Neural Networks for Pattern Recognition, Oxford University Press.
- [136] **Fletcher, R. and Reeves, C.M.**, 1964. Function Minimization by Conjugate Gradients, *Computer Journal*, **7**, 149-154.
- [137] **Powell, M.J.D.**, 1977. Restart Procedures for The Conjugate Gradient Method, *Mathematical Programming*, **12**, 241-254.
- [138] **Beale, E.M.L.**, 1972. A Derivation of Conjugate Gradients, Numerical Methods for Nonlinear Optimization, London:Academic Press.

- [139] Moller, M.F., 1993. A Scaled Conjugate Gradient Algorithm for Fast Supervised Learning, *Neural Networks*, 6, 525-533.
- [140] Fletcher, R., 1987. Practical Methods of Optimization, John Wiley & Sons.
- [141] Dennis, J.E. and Schnabel, R.B., 1983. Numerical Methods for Unconstrained Optimization and Nonlinear Equations, Englewood Cliffs, NJ: Prentice-Hall.
- [142] Himmelblau, D.M., 1972. Applied Nonlinear Programming, McGraw-Hill.
- [143] Battiti, R., 1992. First and Second Order Methods for Learning: Between Steepest Descent and Newton's Method, *Neural Computation*, 4, 141–166.
- [144] Kohonen, T., 1984. Self Organization and Associative Memories, Springer-Verlag, New York.
- [145] Kohonen, T., 1988. Statistical Pattern Recognition with Neural Networks: Benchmark Studies, *Proceedings of The Second Annual IEEE International Conference on Neural Networks*, 1.
- [146] Gersho, A., 1982. On The Structure of Vector Quantizers, *IEEE Transactions on Information Theory*, 17, 157-166.
- [147] Pham, D.T. and Oztemel, E., 1994. Control Chart Pattern Recognition Using Learning Vector quantization Networks, *International Journal of Prod. Res.*, 32, 721-729.
- [148] Pham, D.T. and Oztemel, E., 1993. Control Chart Pattern Recognition Using Combinations of Multi Layer Perceptrons and Learning Vector Quantization Neural Networks, *Journal of Systems and Control Engineering*, 207, 113-118.
- [149] Desieno, D., 1988. Adding a Conscience to Competitive Learning, *Proceedings of The Second Annual IEEE International Conference on Neural Networks*, 1, 117-124.
- [150] Kohonen, T., Barna, G. and Chrisley, R., 1988. Statistical Pattern Recognition with Neural Networks: Benchmarking studies, *International Joint Conference on Neural Networks*, San Diego, CA, 1, 61-68.
- [151] Kohonen, T., 1990. Self Organizing Feature Map, *Proceedings of The IEEE*, 78, 1464-1480.
- [152] Moody, J. and Darken, C., 1988. Learning with Localized Receptive Fields, *Proceedings of the 1988 Connectionist Models Summer School*, San Mateo CA., Carnegie Mellon University, Morgan Kaufman.

- [153] **Moody, J. and Darken, M.**, 1989. Fast Learning in Networks of Locally Tuned Processing Units, *Neural Computation*, **1**, 281-294.
- [154] **Powell, M.J.D.**, 1987. Radial Basis Functions for Multivariable Interpolation: A Review, Algorithms for Approximation, Oxford: Clarendon Press., 143-167.
- [155] **Broomhead, D.S. and Lowe, D.**, 1988. Multivariable Functional Interpolation and Adaptive Networks, *Complex Systems*, **2**, 231-355.
- [156] **Lowe, D.**, 1989. Adaptive Radial Basis Function Nonlinearities and The Problem of Generalization, In *Proceedings of The First IEEE International Conference on Artificial Neural Networks*, London, **6**, 171-175.
- [157] **Jang, J.S.R., Sun, C.T. and Mizutani, E.**, 1997. Neuro-Fuzzy and Soft Computing-A Computational Approach to Learning and Machine Intelligence, Prentice-Hall, Inc.
- [158] **Nowlan, S.J.**, 1989. Maximum Likelihood Competitive Learning, *Advances in Neural Information Processing Systems*, San Mateo, CA, **2**, 574-582.
- [159] **Leonard, J.A. and Kramer, M.A.**, 1991. Radial Basis Functions for Classifying Process Faults, *IEEE Control Systems*, April, **11**, 31-38.
- [160] **Leonard, J.A., Kramer, M.A. and Ungar, M.A.**, 1992. Using Radial Basis Functions to Approximate a Function and Its Error Bounds, *IEEE Transactions on Neural Networks*, **3**, 624-627.
- [161] **German, G. and Gahegan, M.**, 1996. Neural Network Architectures For The Classification Of Temporal Image Sequences, *Computers and Geosciences*, **22**, 969-979.
- [162] **Kavzoglu, T.**, 1999. Determining Optimum Structure for Artificial Neural Networks, *Proceedings of RSS99 Earth Observation, From Data to Information*, University of Wales, 8-10 September, UK, 675-682.
- [163] **Foody, G.M.**, 1999. Hard and Soft Classifications with a Non-Exhaustively Defined Set of Classes, *Proceedings of RSS99 Earth Observation, From Data to Information*, University of Wales, 8-10 September, UK, 63-70.
- [164] **Dreyer, P.**, 1993. Classification of Land Cover Using Optimized Neural Nets on SPOT Data, *Photogrammetric Engineering and Remote Sensing*, **59**, 617-621.
- [165] **Bischof, H., Schneider, W. and Pinz, A.J.**, 1992. Multispectral Classification of LANDSAT Images Using Neural Networks, *IEEE Transactions on Geosciences and Remote Sensing*, **30**, 482-490.

- [166] **Kiang, R.K.**, 1992. Classification of Remotely Sensed Data Using OCR-Inspired Neural Network Techniques, *Proceedings, 12th Annual International Geoscience and Remote Sensing Symposium*, Houston, Tx., May, 1081-1083.
- [167] **Li, R. and Si, H.**, 1992. Multispectral Image Classification Using Improved Backpropagation Neural Networks, *Proceedings, 12th Annual International Geoscience and Remote Sensing Symposium*, Houston, Tx., May, 1078-1080.
- [168] **Crompt, R.F.**, 1991. Automated Extraction of Metadata from Remotely Sensed Satellite Imagery, *Proceedings, ASPRS-ACSM Annual Meeting*, Baltimore, Md., 3, 111-120.
- [169] **Skidmore, A.K., Turner, B.J., Brinkhof, W. and Knowles, E.**, 1997. Performance of a Neural Network: Mapping Forests Using GIS and Remotely Sensed Data, *Photogrammetric Engineering and Remote Sensing*, 63, 501-514.
- [170] **Bruzzone, L., Conese, C., Maselli, F. and Roli, F.**, 1997. Multisource Classification of Complex Rural Areas by Statistical and Neural-Network Approaches, *Photogrammetric Engineering and Remote Sensing*, 63, 523-533.
- [171] <http://www.ci.tuwien.ac.at/docs/services/nnfaq/FAQ2.html#questions>.
- [172] **Herrman, P.D. and Khazenie, N.**, 1992. Classification Multispectral Remote Sensing Data Using a Backpropagation Neural Network, *IEEE Transactions on Geoscience and Remote Sensing*, 30, 81-88.
- [173] **Benedictsson, J.A., Swain, P.H., Ersoy, O.K. and Hong, D.**, 1990. Classification of Very High Dimensional Data Using Neural Networks, *Proceedings, 10th Annual International Geoscience and Remote Sensing Symposium*, College Park, Md., May, 1269-1272.
- [174] **Thackrah, G., Barnsley, M. and Pan, P.**, 1999. Merging, Land Cover Classification from Artificial Neural Networks Using The Sugeno Fuzzy Integral, *Proceedings of RSS99 Earth Observation, From Data to Information*, University of Wales, 8-10 September, UK, 71-78.
- [175] **Magoulas, G.D., Vrahatis, M.N. and androulakis, G.S.**, 1997. Effective Backpropagation Trainig with Variable Stepsize, *Neural Networks*, 10, 69-82.
- [176] **Sun, C., Neale, C.M.U., McDonnell, J.J. and Cheng, H.D.**, 1996. Snow Classification From SSM/I Data over Varied Terrain Using an Artificial Neural Network Classifier, *IEEE Transactions on Geoscience and Remote Sensing*, 35, 133-135.

- [177] **Orlando, J.R., Mann, R. and Haykin, S.**, 1990. Classification of Sea-Ice Images Using a Dual-Polarized Radar, *IEEE Journal of Oceanic Engineering*, July, **15**, 228-237.
- [178] **Berberoglu, S. and Curran, P.J.**, 1998. Optimising The Remote Sensing of Mediterranean Land Cover, *In Proceedings of the 24th Annual Conference of the Remote Sensing Society*, Remote Sensing Society, Nottingham, 103-109.
- [179] **Murai, H. and Omatu, S.**, 1997. Remote Sensing Image Analysis Using a Neural Network and Knowledge Based Processing, *International Journal of Remote Sensing*, **18**, 811-828.
- [180] **Paola, J.D. and Schowengerdt, R.A.**, 1995. A Review and Analysis of Backpropagation Neural Networks for Classification of Remotely Sensed Multispectral Imagery, *International Journal of Remote Sensing*, November, **16**, 3033-3058.
- [181] **Civco, D.L.**, 1991. LANDSAT TM Image Classification With an Artificial Neural Network, *Proceedings, ASPRS-ACSM Annual meeting*, Baltimore, Md., **3**, 67-77.
- [182] **Mulder, N.J. and Spreewers, L.**, 1991. Neural Networks To The Classification Of Remotely Sensed Data, *Proceedings, 11th Annual International Geoscience and Remote Sensing Symposium*, Espoo, Finland, June, 2211-2213.
- [183] **Viera, C.A.O. and Mather, P.M.**, 1999. Visualising The Spatial Accuracy of Classified Images, *Proceedings of RSS99 Earth Observation, From Data to Information*, University of Wales, 8-10 September, UK, 897-904.
- [184] **Short, N.**, 1991. A Real-Time Expert System And Neural Network For The Classification Of Remotely Sensed Data, *Proceedings ASPRS-ACSM Annual Meeting*, Baltimore, Md., **3**, 406-418.
- [185] **McClellan, G.E., Dewitt, R.N., Hemmer, T.H., Matheson, L.N. and Moe, G.O.**, 1989. Multispectral Image Processing With A Three Layer Backpropagation Network, *Proceedings, 1989 International Joint Conference On Neural Networks*, Washington D.C., **1**, 151-153.
- [186] **Lippmann, R.P.**, 1987. An Introduction To Computing With Neural Networks, *IEEE ASSP Magazine*, April, 4-22.
- [187] **Paola, J.D. and Schowengerdt, R.A.**, 1995. A Detailed Comparison of Backpropagation Neural Network and Maximum-Likelihood Classifiers for Urban Land Use Classification, *IEEE Transactions on the Geosciences and Remote Sensing*, **33**, 981-996.

- [188] Paola, J.D., 1994. Neural Network Classification of Multispectral Imagery, *Msc. Thesis*, University of Arizona.
- [189] Dunne, R.A, Campbell, N.A. and Kiiveri, H.T., 1992. Task-Based Pruning, *Proceedings of The 3rd Australasian Conference on Neural Networks*, 166-179.
- [190] Pao, Y.H., 1989. Adaptive Pattern Recognition and Neural Networks, Addison-Wesley, Reading, Ma.
- [191] Rumelhart, D.E. and McClelland, J.L., 1986. Parellel Distributed Processing: Explorations in The Microstructure of Cognition, Cambridge, MA: MIT Press., 1
- [192] Key, J., Maslanic, A. and Schweiger, A.J., 1989. Classification of Merged AVHRR and SMMR Arctic Data with Neural Network, *Photogrammetric Engineering & Remote Sensing*, **55**, 1331-1338.
- [193] Howald, K.J., 1989. Neural Network Image Classification, *In Proceedings of ASPRS-ACSM Fall Convention "From Compass to Computer"*, Cleveland, September, 207-215.
- [194] Decatur, S.E., 1989. Aplication of Neural Networks to Terrain Classification, *In Proceedings of The International Joint Conference on Neural Networks*, Washington DC, 18-22 June, **1**, 283-288.
- [195] Gualtieri, J.A., Withers, J., 1988. Goddard Researchers Simulate Neural Networks Using Parallel Processing, *NASA Information Systems Newsletter*, 12-15.
- [196] Kamgar-Parsi, B., Gualtieri, J.A. and Devaney, J.E., 1990. Clustering with Neural Networks, *Biological Cybernetics*, **63**, 201-208.
- [197] Kwok, R., Hara, Y., Atkins, R.G., Yueh, S.H., Shin, R.T. and Kong, J.A., 1991. Application of Neural Networks to Sea Ice Classification Using Polarimetric SAR Images, *In Proceedings of The International Geoscience and Remote Sensing Symposium*, (IGARSS'91), Espoo, Finland, IEEE Press., June, **1**, 85-88.
- [198] Luttrell, S.P., 1988. Image Compression Using a Neural Network, *In Proceedings of The International Geoscience and Remote Sensing Symposium*, (IGARSS'88), Edinburgh, Scotland, ESA Publications, 1231-1238, September.
- [199] Hernandez, R., Varfis, A., Kanellopoulos, I. and Wilkinson, G.G., 1992. Delopment of MLP/LVQ Hybrid Networks for Classification of Remotely-Sensed Satellite Images, *In Proceedings of The 1992 International Conference on Artificial Neural Networks (ICANN-92)*, Brington,U.K., Elsevier Science Publications (North-Holland), September, **2**, 1193-1196.

- [200] **Wilkinson, G.G., Kontoes, C. and Murray, C.N.**, 1992. Recognition and Inventory of Oceanic Clouds From Satellite Data Using An Artificial Neural Network Technique, *In Proceedings of The International Symposium on Dimethylsulphide Oceans Atmosphere and Climate*, Belgirate(Italy), Commision of The European Communities, Joint Research Centre, October.
- [201] **Lee, J., Weger, R.C., Sengupta, S.G. and Welch, R.M.**, 1990. A Neural Network Approach to Cloud Classification, *IEEE Transactions on Geoscience and Remote Sensing*, **28**, 846-855
- [202] **Kanellopoulos, I, Varfis, A., Wilkinson, G.G. and Megier, J.**, 1991. Classificaion of Remotely Sensed Satellite Images Using Multi-Layer Perceptron Networks, *In Proceedings of the 1991 International Confernce on Artificial Neural Networks (ICANN-91)*, Espoo, Finland, Elsveier Science Publications (North-Holland), June, **2**, 1067-1070.
- [203] **Ersoy, O.K. and Hong, D.**, 1989. Hierarchical Neural Networks Involving Nonlinear Spectral Processing, *In Proceedings of The International Joint Confernce on Neural Networks*, Washington DC, 18-22 June, **2**, 264.
- [204] **Liu, Z.K. and Xiao, J.Y.**, 1991. Classification of Remotely Sensed Image Data Using Artificial Neural Networks, *International Journal of Remote Sensing*, **12**, 2433-2438.
- [205] **Ryan, T.W., Sementelli, P.J., Yuen, P. and Hunt, B.R.**, 1991. Extraction of Shoreline Features by Neural Nets and Image Processing, *Photogrammetric Engineering and Remote Sensing*, **57**, 947-955.
- [206] **Dawson, M.S., Fung, A.K. and Manry, M.T.**, 1992. Sea Ice Classification Using Fast Learning Neural Networks, *In Proceedings of The International Geoscience and Remote Sensing Symposium (IGARSS'92)*, Houston, Texas, IEEE Press, May, **2**, 1070-1071.
- [207] **Kahny, D. and Wiesbeck, W.**, 1991. Optimum Input Parameters For Classification Of Multifrequency Polarimetric SAR Data Using Neural Networks, *In Proceedings of International Geoscience and Remote Sensing Symposium (IGARSS'91)*, Espoo, Finland, IEEE Press, June, **4**, 2157-2160.
- [208] **Kahny, D., Cichon, D.J., Schmitt, K. and Wiesbeck, W.**, 1992. Classification Of SAR Data Using Neural Networks And Polarimetric Filters, *In Proceedings of the International Geoscience and Remote Sensing Symposium (IGARSS'92)*, Houston, Texas, IEEE Press, May, **1**, 59-61.
- [209] **Downey, I.D., Power, C.H.,Kanellopoulos, I. and Wilkinson, G.G.**, 1992. A Performance Comparision Of LANDSAT TM Land Cover Classification Based On Neural Network Techniques And Traditional

Maximum Likelihood And Minimum Distance Algorithms, *In Proceedings of the 18th Annual Conference of The UK Remote Sensing Society Entitled: Remote Sensing from Research to Operation*, Dundee, Scotland, September, 518-528.

- [210] **Wilkinson, G.G., Kanellopoulos, I., Kontoes, C. and Megier, J.**, 1992. A Comparision Of Neural Network And Expert System Methods For Analysis Of Remotely Sensed Imagery, *In Proceedings of The International Geoscience and Remote Sensing Symposium (IGARSS'92)*, Houston, Texas, IEEE Press, May, 1, 62-64.
- [211] **Salu, Y. and Tilton, J.**, 1993. Classification Of Multispectral Image Data By The Binary Diamond Neural Network And By Nonparametric, Pixel By Pixel Methods, *IEEE Transactions on Geoscience and Remote Sensing*, **31**, 606-617.
- [212] **Augusteijn, M.F., Clemens, L.E. and Shaw, K.A.**, 1995. Performance Evaluation Of Texture Measures For Ground Cover Identification In Satellite Images By Means Of A Neural Network Classifier, *IEEE Transactions on Geoscience and Remote Sensing*, **33**, 616-626.
- [213] **Cehn, K.S., Tzeng, Y.C., Chen, C.F. and Kao, W.L.**, 1995. Land-Cover Classificaiton Of Multispectral Imagery Using A Dynamic Leraning Neural Network, *Photogrammetric Engineering and Remote Sensing*, **61**, 403-408.
- [214] **Foody, G.M.**, 1995. Land Cover Classification By An Artificial Neural Network With Ancillary Information, *International Journal Of Geographical Information Systems*, **9**, 527-542.
- [215] **Foody, G.M., Mcculloch, M.B. and Yates, W.B.**, 1995. Classificaiton Of Remotely Sensed Data: Issues Related To Training Data Characteristics, *Photogrammetric Engineering and Remote Sensing*, **61**, 391-402.
- [216] **Foody, G.M.**, 1995. Using Prior Knowledge In Artificial Neural Network Classificaiton With A Minimal Training Set, *International Journal Remote Sensing*, **16**, 301-312.
- [217] **Kanellopoulos, I., Wilkinson, G.G. and Chiuderi, A.**, 1994. Land Cover Mapping Using Combined LANDSAT TM Imagery And Textural Features From ERS-1 Synthetic Aperture Radar Imagery, *In Image And Signal Processing for Remote Sensing*, September, 332-341.
- [218] **Wilkinson, G.G., Folving, S., Kanellopoulos, I., McCormick, N., Fullerton, K. and Meiger, J.**, 1995. Forest Mapping From Multi-Source Satellite Data Using Neural Network Calssifier—An Expreiment In Portugal, *Remote Sesning Reviews*, **12**, 83-106.

- [219] Hara, Y., Atkins, R.G., Yueh, S.H., Shin, R.T. and Kong, J.A., 1994. Application Of Neural Networks To Radar Image Classification, *IEEE Transactions On Geoscience And Remote Sensing*, **32**, 100-109.
- [220] Paola, J.D. and Schowengerdt, R.A., 1994. Comparison Of Neural Networks To Standard Techniques For Image Classification And Correlation, *In Proceedings Of The International Geoscience And Remote Sensing Symposium (IGARSS'94)*, Pasadena, California, IEEE press, August, 1404-1406.
- [221] Fierens, F., Kanellopoulos, I., Wilkinson, G.G. and Megier, J., 1994. Comparison And Visualisation Of Feature Space Behaviour Of Statistical And Neural Classifiers Of Satellite Imagery, *Proceedings Of The International Geoscience And Remote Sensing Symposium (IGARSS'94)*, Pasadena, California, IEEE Press, August 4, 1880-1882.
- [222] Wilkinson, G.G., Fierens, F. and Kanellopoulos, I., 1995. Integration Of Neural And Statistical Approaches In Spatial Data Classification, *Geographical Systems*, **2**, 1-20.
- [223] Schaale, M. and Furrer, R., 1995. Land Surface Classification By Neural Networks, *International Journal of Remote Sensing*, **16**, 3003-3032.
- [224] Benedictsson, J.A., Sveinsson, J.R. and Arnason, K., 1995. Classification And Feature Extraction Of AVIRIS Data, *IEEE Transactions on Geoscience and Remote Sensing*, **33**, 1194-1205.
- [225] Lee, C. and Landgrebe, D.A., 1993. Feature Extraction Based On Decision Boundaries, *IEEE Transactions On Pattern Analysis and Machine Intelligence*, **15**, 338-400.
- [226] Chen, Z., Davis, D.T., Tsang, L., Hwang, J.N. and Chang, A.T.C., 1992. Inversion Of Snow Parameters By A Neural Network With Iterative Inversion, *In Proceedings of the International Geoscience and Remote Sensing Symposium (IGARSS'92)*, Houston, Texas, IEEE Press, May, **2**, 1061-1063.
- [227] Zurk, L.M., Davis, D., Njoku, E.G., Tsang, L. and Hwang, J.N., 1992. Inversion Of Parameters For Semi-Arid Regions By A Neural Network, *In Proceedings of the International Geoscience and Remote Sensing Symposium (IGARSS'92)*, Houston, Texas, IEEE Press, May, **2**, 1075-1077.
- [228] Pierce, L.E., Sarabandi, K., Stiles, J.M. and Ulaby, F.T., 1992. Application Of An Artificial Neural Network In A Canopy Scattering Model Inversion, *In Proceedings Of The International Geoscience and Remote Sensing Symposium (IGARSS'92)*, Houston, Texas, IEEE Press, May, **2**, 1067-1069.

- [229] Dunne, R.A., Campbell, N.A. and Kiiveri, H.T., 1993. Classifying High Dimensional Spectral Data by Neural Networks, *Proceedings of the 4th Australian Conference on Neural Networks*.
- [230] German, G. and Gahegan, M., 1996. Neural Network Architectures for The Classification of Temporal Image Sequences, *Computers and Geosciences*, **22**, 969-979.
- [231] Kanellopoulos, I. and Wilkinson, G.G., 1997. Strategies And Best Practice For Neural Network Image Classification, *International Journal of Remote Sensing*, **18**, 711-725.
- [232] Benediktsson, J.A. and Sveinsson, J.R., 1997. Multisource Data Classification and Feature Extraction with Neural Networks, *International Journal of Remote Sensing*, **18**, 727-740.
- [233] Foody, G.M. and Arora, M.K., 1997. An Evaluation of Some Factors Affecting The Accuracy of Classification by An Artificial Neural Network, *International Journal of Remote Sensing*, **18**, 799-810.
- [234] Kamata, S. and Kawaguchi, E., 1993. A Neural Net Classifier for Multi-Temporal LANDSAT Images Using Spatial and Spectral Information, *IEEE Proceedings of 1993 International Joint Conference on Neural Networks*, **2**, 199-202.
- [235] Rollet, R., Benie, G.B., Li, W., Wang, S. and Boucher, J-M., 1998. Image Classification Algorithm Based on The RBF Neural Network and K-Means, *International Journal of Remote Sensing*, **19**, 3003-3009.
- [236] Ito, Y. and Omatu, S., 1999. Extended LVQ Neural Network Approach to Land Cover Mapping, *IEEE Transactions on Geoscience and Remote Sensing*, January, **37**, 313-317.
- [237] Bruzzone, L., 1999. A Technique For The Selection Of Kernel-Function Parameters in RBF Neural Networks for Classification of Remote-Sensing Images, *IEEE Transactions on Geoscience and Remote Sensing*, **37**, 1179-1184.
- [238] Civco, D. and Waug, Y., 1994. Classification of Multispectral, Multitemporal, Multisource Spatial Data Using Artificial Neural Networks, *ASPRS/ACSM Annual Convention & Exposition*, Reno, 123-133.
- [239] Civco, D.L., 1993. Artificial Neural Networks for Land-Cover Classification and Mapping, *International Journal of Geographical Systems*, **7**, 173-186.
- [240] Nordahl, B., 1996. Comparison of Statistical Methods and Neural Networks in A Post-Object Classification for Forestry Registration,

International Archives of Photogrammetry and Remote Sensing, Vienna, **31**, 542-546.

- [241] **Özkan, C.**, 1998. Uzaktan Algılama Verileriyle Orman Yangını Analizi, *Yüksek Lisans Tezi*, İTÜ Fen Bilimleri Enstitüsü, Haziran.
- [242] **Yun, Z.**, 1999. Optimization Of Building Detection in Satellite Images by Combining Multispectral Classification and Texture Filtering, *Photogrammetry and Remote Sensing*, **54**, 50-60.
- [243] **Augusteijn, M.F. and warrender, C.E.**, 1998. Wetland Classification Using Optical and Radar Data and Neural Network Classification, *International Journal of Remote Sensing*, **19**, 1545-1560.



ÖZGEÇMİŞ

1973 yılında Tokat'ın Erbaa ilçesinde doğdu. İlk ve orta öğrenimini Kırıkkale'de tamamladı. Liseyi Ankara'da Tapu ve Kadastro Meslek Lisesi'nde bitirdi. 1991-1992 yılları arası Kırıkkale Kadastro Müdürlüğü'nde teknisyen olarak çalıştı. 1992 yılında İstanbul Teknik Üniversitesi İnşaat Fakültesi Jeodezi ve Fotogrametri Mühendisliği Bölümüne girdi. 1996 yılında lisans diplomasını alıp aynı yıl İTÜ Fen Bilimleri Enstitüsü Jeodezi ve Fotogrametri Mühendisliği programında yüksek lisans eğitime başladı. Yüksek lisans programını 1998 yılında bitirip aynı bölümde Doktora programına başladı.

1998 yılından itibaren Erciyes Üniversitesi Mühendislik Fakültesi Jeodezi ve Fotogrametri Mühendisliği Bölümünde Araştırma Görevlisi olarak çalışmaktadır.

Evli olup bir kızı vardır.