


**GÖRÜNTÜ SINIFLANDIRMASI İÇİN YAPAY SİNİR
AĞLARININ ANALİZ VE OPTİMİZASYONU**

DOKTORA TEZİ
Y. Müh. Ozan ARSLAN
(No: 501932031)

112262

T.C. YÜKSEKÖĞRETİM KURULU
DOKÜMANTASYON MERKEZİ

Tezin Enstitüye Verildiği Tarih : 23 Haziran 2001
Tezin Savunulduğu Tarih : 18 Ekim 2001

Tez Danışmanı : Prof.Dr. Oğuz MÜFTÜOĞLU (İ.T.Ü.) 
Diğer Jüri Üyeleri : Prof.Dr. Cankut ÖRMECİ (İ.T.Ü.) 
Prof.Dr. Zekai ŞEN (İ.T.Ü.) 
Prof.Dr. Cahid AYBET (İ.K.Ü.) 
Prof.Dr. Ruhi KAYKAYOĞLU (Bahçeşehir Ü.) 

EKİM 2001

ÖNSÖZ

Bu tez çalışmasının hazırlanması sürecinde her türlü desteği veren, danışman hocam Sayın Prof. Dr. Oğuz MÜFTÜOĞLU' na değerli katkılarından dolayı, teşekkürü bir borç bilirim. Bilimsel nitelikteki önerileri ve desteğinin yanısıra göstermiş olduğu yakın ilgiden dolayı da ayrıca teşekkür ederim. Lisansüstü öğrenimim sırasında sayısal görüntü işleme ile ilgili konuları öğrenmemi sağlayan Sayın Prof. Dr. Cankut ÖRMECİ' ye teşekkürlerimi sunarım.

Tez çalışması sırasında gösterdiği sabır ve ilgiden dolayı eşim Neşe ve küçük oğlum Arda' ya teşekkür ederim.

Uygulamalar için gerekli olan ham görüntüleri sağlayan Dr. Şinasi Kaya' ya ve emeği geçen diğer tüm hocalarıma teşekkür ederim.

Ekim 2001

Ozan ARSLAN

İÇİNDEKİLER

KISALTMALAR	v
TABLO LİSTESİ	vi
ŞEKİL LİSTESİ	vii
SEMBOL LİSTESİ	viii
ÖZET	ix
SUMMARY	xii
1. GİRİŞ	1
2. GÖRÜNTÜ SINIFLANDIRMASINDA YAPAY SİNİR AĞI KULLANIMI ÜZERİNE BİR ARAŞTIRMA	8
3. GÖRÜNTÜ SINIFLANDIRMA ALGORİTMALARI	21
3.1. Parametrik Sınıflandırma Algoritmaları ve Bazı Dezavantajlar	22
3.1.1. Paralelyüz (parallelepiped) sınıflandırma yöntemi	23
3.1.2. En büyük benzerlik (Maximum Likelihood) sınıflandırma yöntemi	24
3.1.3. En küçük uzaklık (Minimum Distance) sınıflandırma yöntemi	26
3.1.4. Mahalanobis sınıflandırma yöntemi	27
3.1.5. Karar Yüzeyleri (decision surfaces- decision boundaries)	27
3.2. Non-parametrik Sınıflandırma Algoritmaları	29
3.2.1. Yapay Sinir Ağları (Artificial Neural Networks)	31
3.2.1.1. Çok-tabakalı algılayıcı sinir ağı (Multilayer Perceptron)	37
3.2.1.2. Yapay sinir ağlarında doğruluk güven tahmini	41
3.2.1.3. Sinir ağlarında doğruluk güven tahmini için yeni bir yöntem	44
3.2.1.4. Sinir ağlarında hızlı çözüm sağlayan yeni bir algoritma tasarımı	48
3.3. Yapay Sinir Ağları Kavramı İçinde İrdelenmesi Gereken Bazı Sınıflandırma Algoritmaları	51
4. YAPAY SİNİR AĞI KULLANILARAK GÖRÜNTÜ SINIFLANDIRMASI VE DOĞRULUK DEĞERLENDİRMESİ - UYGULAMALAR	56
4.1. Problemin Tanımlanması	56
4.2. Uzaktan Algılamada Görüntü Sınıflandırmasının Doğruluk Değerlendirmesi	57
4.3. Uygulama Örnekleri- Landsat TM Görüntü Verilerinin Sınıflandırması	59
5. SONUÇLAR VE ÖNERİLER	80
KAYNAKLAR	84

EKLER

92

ÖZGEÇMİŞ

103



KISALTMALAR

ANN	: Artificial Neural Networks
BP	: Backpropagation
LVQ	: Learning Vector Quantisation
SOFM	: Self- Organising Feature Maps
ART	: Adaptive Resonance Theory
MLP	: Multilayer Perceptron
PDM	: Polynomial Discriminate Method
PNN	: Probabilistic Neural Networks
MLC	: Maximum Likelihood Classification



TABLO LİSTESİ

	Sayfa No
Tablo 4.1. Sinir ağı tekniği ile sınıflandırmada doğruluk değerlendirmesi	65
Tablo 4.2. Ençok benzerlik yöntemi ile sınıflandırmada doğruluk değerlendirmesi	65
Tablo 4.3. Uygulamada kullanılan sinir ağı mimarileri	67
Tablo 4.4. Kullanılan sinir ağı yapıları için güven tahmin değerleri tablosu	70
Tablo 4.5. Aynı ağ yapılarının farklı veri setlerine göre hesaplanan tahmin değerleri	71
Tablo 4.6. Ençok benzerlik yöntemiyle sınıflandırmada doğruluk değerlendirmesi	72
Tablo 4.7. Yapay sinir ağı ile sınıflandırmada doğruluk değerlendirmesi	73
Tablo 4.8. Algoritmalarda kullanılan parametreler	75
Tablo 4.9. Uygulamalarda kullanılan sinir ağlarının çözüm sonucu k.o.h.değerleri	76
Tablo 4.10. Sınıflandırma doğruluk değerlendirmesi sonuçları	77
Table 4.11. Sınıflandırmada doğruluk değerlendirmesi örneği	79

ŞEKİL LİSTESİ

	Sayfa No
Şekil 2.1 : Kanellopoulos'un hiyerarşik sinir ağı mimarisi	9
Şekil 2.2 : Wilkinson'un Bütünleşik Sınıflandırma Prosedürü	11
Şekil 3.1 : İki boyutta paralelyüz sınıflandırma	23
Şekil 3.2 : İki normal olasılık dağılımı	24
Şekil 3.3 : Çeşitli sınıflandırma yöntemlerine ait karar yüzeyleri	28
Şekil 3.4 : Yapay sinir ağı yapısı	32
Şekil 3.5 : Doğal ve yapay nöronun görünümü	33
Şekil 3.6 : Sınıflandırmada kullanılan bir sinir ağı yapısı örneği	34
Şekil 3.7 : Eğri uydurma- Aşırıuyuma problemi	35
Şekil 3.8 : Nöron Modeli	35
Şekil 3.9 : Genel etkinlik fonksiyonları	36
Şekil 3.10 : Sinir ağı tabaka yapısı	36
Şekil 3.11 : Üç- tabakalı sinir ağı yapısı	37
Şekil 3.12 : Çok- tabakalı sinir ağı	38
Şekil 3.13 : Tek ve çok-tabakalı sinir ağlarının oluşturduğu karar sınırları	39
Şekil 3.14 : Global minimum ve gradyen düşme kuralı	39
Şekil 3.15 : Sinir ağlarında doğruluk güven tahmini yazılımı	47
Şekil 3.16 : Hızlı Yapay Sinir Ağı Yazılımı	50
Şekil 3.17 : Olasıcı sinir ağı yapısı	53
Şekil 4.1 : Hata matrisinin şematik gösterimi	57
Şekil 4.2 : HYSA Yazılım Menüsü	60
Şekil 4.3 : Sınıflandırma model dosya tipi	61
Şekil 4.4 : Ağ mimarisi seçimi menüsü	61
Şekil 4.5 : Sinir ağı işlem seçenekleri	62
Şekil 4.6 : Çözüm algoritması değerlerinin görünümü	63
Şekil 4.7a : HYSA yazılımı ile sınıflandırılan görüntü	64
Şekil 4.7b : HYSA yazılımı ile sınıflandırılan görüntünün bir bölümü	64
Şekil 4.8 : Hata grafiği	65
Şekil 4.9 : Uygulamada kullanılan sinir ağı modeli	67
Şekil 4.10 : Yapay sinir ağlarında güven tahmini yazılımı	68
Şekil 4.11 : Güven değeri hesaplama menüsü	69
Şekil 4.12 : En çok benzerlik yöntemine göre sınıflandırılmış görüntü	72
Şekil 4.13 : Yapay sinir ağı sınıflandırma görüntüsü	74
Şekil 4.14 : Olasıcı sinir ağı sınıflandırması doğruluk değerlendirmesi	76
Şekil 4.15 : Sinir ağı sınıflandırması toplam doğruluk grafiği	78

SEMBOL LİSTESİ

η	: öğrenme oranı
w	: ağırlık vektörü
o	: gerçekleşen sonuç
d	: istenen sonuç
E	: sonuç (çıkış) hatası
n	: toplam giriş vektörü
i	: giriş vektörü
Δw	: ağırlık düzeltmesi
α	: momentum terimi
δ	: hata terimi
H	: multispectral veri seti
T	: deneme seti
c	: sınıflar
X	: gizli tabakalar

GÖRÜNTÜ SINIFLANDIRMASI İÇİN YAPAY SINIR AĞLARININ ANALİZ VE OPTİMİZASYONU

ÖZET

İnsan beyninin problem çözme, anımsama, sentez yapma ve bilgi kazanımı gibi güçlü yetenekleri, farklı bilimlerden birçok bilim adamını bu işlevleri modellendirebilmek için esin kaynağı olmuştur. Yapay sinir ağları, beynin karmaşık işlemlerini basit bir şekilde benzeştiren (taklit eden) model formları olarak düşünülebilir. Bu teknikler tıp, iş dünyası, bilgisayar vb. birçok alanda geliştirilmekte ve kullanılmaktadır.

Uzaktan algılamada ise bu teknikler, arazi- örtü sınıflandırması, jeolojik haritalama, bulut- örtüsü sınıflandırması ve çeşitli kaynaklardan elde edilen verilerin sınıflandırması gibi çok çeşitli sınıflandırma problemlerinde kullanılmaktadır. Yapay sinir ağı tekniklerinin gücü şu özgün niteliklerinden kaynaklanmaktadır; parametrik olmayan yapısı, istenilen biçimde karar sınırları oluşturabilme yeteneği, farklı veri türlerine uyum yeteneği ve sınıflandırma kalitesini arttırabilecek bulanık (fuzzy) sonuç değerleri.

Son yıllarda yeryüzü çevresinin değerlendirilmesi ve sınıflandırılması gittikçe artan bir şekilde önem kazanmıştır. Uzaktan algılama verileri bu tür değerlendirmeler için temel verileri sağlar. Uydu algılayıcılarının nesnelerin çeşitli spektral (yansıma) değerlerini ayırt edebilme yeteneği nedeniyle, uydu görüntüleri sınıflandırma için mükemmel bir araçtır. Sinir ağlarının uzaktan algılamadaki kullanımı görece yenidir. Buna rağmen geçen son birkaç yılda yayınlanan uygulama sayısında artış görülmektedir. Uygulamaların çoğunda geri-yayılma (backpropagation) algoritması ile çalıştırılan “çok-tabakalı algılayıcı sinir ağı” (multilayer perceptron neural network) kullanılmıştır.

Son araştırmalar sinir ağlarının uzaktan algılamada bir sınıflandırma yöntemi olarak kullanıldığında etkin olabileceğini göstermiştir. Multispectral görüntülerin sınıflandırılmasında sinir ağlarının uygulamaları hızla artmaktadır. Bunun nedeni şu özelliklerinden kaynaklanmaktadır: i-) standart sınıflandırma yöntemlerine ilginç bir alternatif oluşturan “öğrenme” yeteneği, ii-) olasılık modeli ile ilgili hiçbir varsayım yapmaması, iii-) özellik uzayında yüksek dereceden lineer olmayan “karar sınırları” oluşturma yeteneği.

Uzaktan algılanmış görüntülerden arazi kullanım haritalarının elde edilmesi, öncelikle sınıflandırma işlemine bağlıdır. Geçen on yılda, uzaktan algılama verileri için, ileri sınıflandırma algoritmalarının (istatistiksel, bilgi-tabanlı, sinir ağı ve hibrid yöntemler) geliştirilmesi için çok çaba harcanmıştır.

Uzaktan algılama verilerinin sayısal analizi için en çok kullanılan yöntem kontrollü sınıflandırmadır. Bu yöntem bir görüntü içindeki piksellere, uygun algoritmalar kullanılarak, arazideki özel örtü sınıflarını temsil eden etiket bilgilerinin atanması

esasına dayanır. Bu algoritmalar arasında “en çok benzerlik sınıflandırma yöntemi” şu anda en çok kullanılan ve bilinen yöntem olup diğer sınıflandırma yöntemleriyle karşılaştırıldığında standart bir sınıflandırma rutini haline gelmiştir. Bu yöntem, olasılık yoğunluk fonksiyonunun öncel olarak varsayılmak zorunda olduğu parametrik sınıflandırma yöntemine dahildir. Eğer gerçek olasılık yoğunluk fonksiyonu, model tarafından varsayılan fonksiyondan farklı ise, düşük bir “en çok benzerlik sınıflandırma” doğruluğu elde edilebilir. Son yıllarda araştırmacılar standart parametrik sınıflandırma tekniklerinin bu olumsuzluğunu gidermek için; parametrik - olmayan sınıflandırma yöntemleri geliştirmeye çalışmaktadırlar ve Yapay Sinir Ağları, uydu görüntülerinin güvenli sınıflandırılması için uygun bir yöntem olarak kabul edilmektedir. Sinir ağları yöntemi en çok benzerlik yöntemine göre, verilerin istatistiği üzerinde herhangi bir varsayım yapmadığı için potansiyel bir üstünlüğe sahiptir.

Sinir Ağları; giriş verileri üzerinde tahmin edici bir işleve sahip olması ve “öğrenebilmesi” nedeniyle bir yapay zeka türünü oluşturur. Öğrenme işlemini benzeştiren çok sayıda yapay zeka modeli için birçok algoritma geliştirilmiştir. Bunlar çok basit matematik modellerden, binlerce değişkenin kullanıldığı son derece karmaşık modellere kadar bir diziyi kapsar. Tanım olarak sinir ağları; karmaşık transfer problemlerinin çözümü için, birlikte işleyen-birbiriyle bağlantılı, lineer olmayan basit hesaplama birimleri (nöron)nden oluşmaktadır.

Günümüzde en çok kullanılan sinir ağı sınıflandırma yöntemi çok tabakalı algılayıcı sinir ağı (multilayer perceptron network : MLP) olup geniş biçimde analiz edilmiş ve birçok öğrenme algoritmaları geliştirilmiştir. MLP, kontrollu sinir ağı türüne aittir. MLP sinir ağı normal olarak geriyayılma (backpropagation) algoritması ile çalıştırılır. Sınıflandırma problemlerinin çözümünde farklı mimarilere (giriş nöronların sayısı, gizli tabakalar, çıkış nöronların sayısı, hedeflenen sonuç, etkinlik fonksiyonları, v.b.) sahip geri yayılma algoritması cesaretlendirici sonuçlar göstermiştir.

Sinir ağı yönteminin temel handikapı , ağıın çalıştırılması (train) için çok fazla zaman gerektirmesidir, ancak; uygun bir öğrenme parametresi kullanılarak gereken zaman azaltılabilir. İşlem zamanının fazlalığına rağmen, multispectral sınıflandırma için yapay sinir ağlarının, standart sınıflandırma daha doğru olduğu görülmüştür.

Uzaktan algılamada yapay sinir ağlarının birçok ilginç kullanımı olmuştur, bunun nedeni; görüntü sınıflandırmasında sinir ağlarının; uzaktan algılama ile diğer yardımcı arazi bilgilerinin integrasyonuna olanak tanımasıdır. En çok benzerlik ve enyakın komşuluk sınıflandırma yöntemi gibi klasik sınıflandırma yöntemleri, yalnızca uydu görüntü band bilgilerine uygulanabilmektedir. Sinir ağları; uydu spektral verileri, yardımcı arazi kullanım bilgileri (eğim, görünüm, yükseklik v.b.) ve arazi sınıfları arasındaki lineer ve lineer olmayan bağlantıları sağlamaktadır.

Bir yapay sinir ağının başarılı biçimde tasarımı; ağıın uygun çalıştırılması kadar doğruluk özelliklerinin belirlenebilmesine de bağlıdır. Bu tezin temel amaçlarından birisi, belirlenen doğrulukta sinir ağlarının etkin ve hızlı bir şekilde çalıştırılması için bir yöntem geliştirmektir. Bu amaçla, çalıştırılan sinir ağlarının kullanıcı- tanımlı doğruluk derecesinde olmasını garanti edecek şekilde, istatistik örnekleme teorisine dayalı bir algoritma geliştirilecektir. Algoritmada ele alınan yaklaşım, doğruluk tahmininde güven aralıklarının kurulmasında “binom denemeler kavramı” ndan yararlanmaktadır. Algoritmanın uygulanması için “Yapay Sinir Ağlarında Güven Tahmini” adında bir yazılım geliştirilmiştir. Yazılım yardımıyla binom teoremi kullanılarak, sinir ağları belirlenen doğruluk derecesinde ve güven düzeyinde çalıştırılabilecektir.

Çok- tabakalı sinir ağıları (MLP) genellikle geriyayılma algoritması ile çalıştırılır, fakat bu algoritmanın bazı dezavantajları vardır. Bu algoritma yerine, optimizasyon problemini çözmek için Levenberg- Marquardt yönteminin kullanılmasına karar verilmiştir. Bu amaçla, bir algoritma (ve yazılımı: HYSAs) tasarlanmıştır. Etkin ve hızlı çalıştırma için, Levenberg- Marquardt optimizasyon yönteminin bir varyasyonu geliştirilmiştir. Bu yöntemin önemli bazı avantajları; hızlı oluşu, yerel minimuma yakınsama garantisi, sayısal kesinliği ve enaz sayıda kullanıcı- tanımlı giriş değeri gerektirmesidir. Bu üstünlükler, uygulaması ve kullanımı kolay olması düşünülen bir yazılım aracı (tool) için önemli özelliklerdir. Yazılım yalnızca ileri- itilimli çok tabakalı sinir ağıları için tasarlanmıştır.

Tez içinde geliştirilen yazılımlar kullanılarak, multispektral görüntü sınıflandırmasında sinir ağı teknikleri standart sınıflandırma teknikleri ile karşılaştırılmıştır. Bu çalışmanın temel amaçları : i-) klasik ve sinir ağı sınıflandırma yöntemleriyle elde edilen sonuçları karşılaştırmak, ii-) yeni algoritma yardımıyla farklı sinir ağı mimarilerinin performansını incelemek, iii-) geliştirilen yeni güven tahmin yöntemini gerçekleştirmek, iv-) görüntü sınıflandırması için yapay sinir ağlarını analiz etmek.

Sonuç olarak yapay sinir ağı teknolojileri; uzaktan algılama görüntülerinin sınıflandırılması için klasik yöntemlere iyi ve etkin bir alternatif olarak düşünülebilir. Başka bir deyişle, sinir ağıları; model sınıflandırma çalışmalarının farklı türlerine yenilikler getiren bir araç olarak değerlendirilmelidir.

THE ANALYSIS AND OPTIMISATION OF ARTIFICIAL NEURAL NETWORKS FOR IMAGE CLASSIFICATION

SUMMARY

The powerful capabilities for knowledge acquisition, recall, synthesis, and problem solving of the human brain have inspired scientists from different disciplines to attempt to model its operations. Artificial Neural Networks (ANN) can be thought of as forms of models imitating the complicated brain processing in a very simple way. These techniques have been developed and used in a wide range of fields including medicine, business and computer processing.

In remote sensing, they have been used for various classification problems such as land- cover classification, geological mapping, multisource data classification and cloud- cover classification. The power of artificial neural network techniques rests in their unique advantages, including; non- parametric nature, arbitrary decision boundary capabilities, easy adaptation to different types of data and input structures and fuzzy output values that can enhance classification.

Over the past several years, increasing emphasis has been placed on the classification and assessment of the earth's environment. Remotely sensed data, such as satellite imagery, provides the basic data for making such assessments. Satellite imagery provides an excellent tool for classification because of the ability of satellite sensors to differentiate between the various spectra of objects. Each object has unique spectral reflectance properties, making identification and correlation possible. The use of neural networks in remote sensing is relatively new. However during the last few years the number of reported applications has been steadily increasing. The majority of applications have used the multi-layer perceptron neural (MLP) network trained with the back-propagation algorithm. The analysis has been carried out on a variety of remotely-sensed data including optical high and low resolution multi-spectral imagery.

Recent studies have demonstrated that neural networks can be effective when used as a classifier of remote sensing data. The application of neural networks to the classification of multispectral images is increasingly emerging. This is due to the following characteristics: i-) their ability of learning provides an interesting alternative to the standard classification methods, ii-) they make no assumptions about the probabilistic model to be made, iii-) they are capable of forming highly non-linear decision boundaries in the feature space.

The derivation of land cover maps from remotely-sensed images depends primarily on the classification process in which a mapping is performed from the multispectral image space to the land cover class space. Much effort has been expended in the last decade to develop improved classification algorithms for remotely sensed data using for example statistical, knowledge-based, neural and hybrid or combined methods.

Supervised classification is the procedure most often used for quantitative analysis of remotely sensed images. It rests upon using suitable algorithms to label the pixels in an image as representing particular ground cover classes. A variety of algorithms is available for this, ranging from those based upon probability distribution models for the classes of interest to those in which the multispectral space is partitioned into class-specific regions using optimally located surfaces. Among these algorithms the maximum likelihood classification is presently the most widely known and utilized, and it is also used as a standard classification routine against which other classification algorithms are compared. Maximum likelihood classification belongs to a parametric classification method where the underlying probability density function must be assumed a priori. We may obtain a poor maximum likelihood classification performance if the true probability density function is different from that assumed by the model. In recent years, researchers have tried to provide non-parametric classification methods to overcome this disadvantage of the standard (parametric) classification techniques, and Artificial Neural Networks have been proposed as a method suitable for the efficient classification of satellite remote sensing images. The neural network method has a potential advantage over maximum-likelihood in that it does not require any assumption about the underlying statistics of the data.

Neural networks are a form of artificial intelligence that can learn and be used in a predictive role based on input training data. Many algorithms have been developed for use in artificial intelligence models to simulate the learning process. These range from very simple mathematical models, to extremely complex models using thousands of variables and auto-associative routines. By definition, neural networks are composed of simple non-linear computational units called neurons that are linked together and work cooperatively to solve complex mapping problems.

The most widely used neural classifier today is multilayer perceptron network which has also been extensively analysed and for which many learning algorithms have also been developed. The MLP belongs to the class of supervised neural networks. Multilayer perceptrons are normally trained with the backpropagation algorithm. The backpropagation algorithm with different architectures (number of input neurons, hidden layers, number of output neurons, desired output, activation functions etc.) shows encouraging results in solving classification problems. The main drawback to the neural network method is the greatly increased time for the training of the net, which can be reduced, however, with an adaptive learning rate parameter. Despite the increased processing time, the ANN was found to be more accurate than standard techniques (e.g. max. likelihood) for multispectral classification.

Neural networks have found many interesting uses in remote sensing because they allow integration of remote sensing and other complementary landuse information in image classification. Classical classifiers, such as maximum likelihood and nearest neighbour classifiers, have been primarily applicable with only satellite image band information. Neural networks allow for linear and non-linear mappings between satellite spectral data, complementary landuse information (e.g. slope, aspect and elevation), and landuse classes.

The successful design of an ANN depends on the proper training of the network as well as the ability to characterize the accuracy of its approximation. One of the main object of this thesis is to develop a methodology for efficient and fast training neural networks, with specified accuracy. For an ANN to be useful in classification procedure, there must be a means of quantifying its accuracy. To this end, a training algorithm based on statistical sampling theory, will be developed and presented, which guarantees that the trained networks provide a user-specified degree of accuracy. The approach taken in the algorithm is to follow a binomial

experimentation concept in order to establish confidence intervals on the accuracy of the ANN' s approximation. To implement the algorithm a software has been developed called “ Yapay Sinir Ağlarında Güven Tahmini Yazılımı (in Turkish)”. With the aid of this software using binomial theorems, the algorithm is to train neural networks with quantified degree of accuracy, given a confidence level.

Multilayer perceptron neural networks are normally trained with the backpropagation algorithm but this algorithm has some shortcomings. Instead of using this algorithm, it has been decided to use the so-called Levenberg- Marquardt method for solving the optimization. For this purpose an algorithm and its software called HYSÄ (Hızlı Yapay Sinir Ağı) has been designed and developed. For fast and efficient training, a variation of Levenberg- Marquardt method is fulfilled. Some important advantages of this method are speed, guaranteed converge to a local minima, numerical robustness and minimal user- specified inputs. Such advantages are important properties in making a user-friendly, easy- to- apply software tool. The software is designed to implement feedforward multilayer perceptrons.

By using the softwares developed in this thesis, neural network techniques for multispectral image classification are compared to the standard classification techniques. The main objectives of this work are: i-) to compare the results obtained using conventional and neural classifiers, ii-) to study the performances of several neural network architectures by using the new algorithm , iii-) to implement the new confidence estimation method developed, iv-) to analyze artificial neural networks for image classification.

As a conclusion, the neural network technologies may be considered as a good alternative to the conventional methods for classification of remotely sensed images. In other words, neural networks can be seen as a new revolutionary kind of tool for different kinds of pattern recognition tasks.

1. GİRİŞ

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

Geçen on yılda, uzaktan algılama verileri için, ileri/ gelişmiş sınıflandırma algoritmalarının (istatistiksel, bilgi bazlı, sinir ağları, hibrid yöntemler,...vb.) geliştirilmesi için çok çaba harcanmıştır. Son araştırmalar "Yapay Sinir Ağları"nın uzaktan algılamada bir sınıflandırma yöntemi olarak, etkin biçimde kullanılabileceğini göstermiştir.

Multispektral (çok bandlı) görüntülerin sınıflandırılmasında Yapay Sinir Ağları (Artificial Neural Networks) uygulamaları hızla artmaktadır. Bunun nedeni sinir ağlarının bazı üstün niteliklerinden kaynaklanmaktadır. Parametrik olmayan yapısı, standart sınıflandırma yöntemlerine ilginç bir alternatif oluşturan "öğrenme" yeteneği, olasılık modeli ile ilgili herhangi bir varsayım yapmaması, özellik uzayında yüksek dereceden lineer- olmayan "karar sınırları/ yüzeyleri" (decision boundary) oluşturma yeteneği ve farklı veri türlerine uyum yeteneği önemli özelliklerindendir.

Yapay sinir ağlarının önemli bir diğer avantajı da uzaktan algılama verileri ile diğer yardımcı arazi bilgilerinin integrasyonuna olanak tanımasıdır. Standart sınıflandırma yöntemleri yalnızca uydu görüntü band (kanal) bilgilerine uygulanabilirken sinir ağları, bu bilgilere ek olarak yardımcı arazi bilgilerinin (eğim, görünüm, yükseklik,...vb.) de kullanımına imkan vermektedir. Bu da sınıflandırmanın kalitesini arttırmaktadır.

Görüntü sınıflandırılmasında kullanılan standart yöntemler, parametrik sınıflandırma algoritmaları grubuna dahildir. Yani, özel bir sınıfın istatistik dağılıma (genellikle normal dağılım) sahip olduğu varsayılarak, sınıflandırma işleminde bu dağılımın parametreleri tahmin edilmektedir. Burada olasılık yoğunluk fonksiyonu öncül olarak varsayılmak zorundadır. Eğer gerçek olasılık yoğunluk fonksiyonu, kullanılan

sınıflandırma modeli tarafından varsayılan fonksiyondan/ dağılımdan farklı ise iyi bir sınıflandırma doğruluğu elde edilemez. Dolayısıyla, standart sınıflandırma tekniklerinin kapasitesi (duyarlılığı), kullanılan verinin olasılık, dağılımına doğrudan bağımlıdır. Örneklem veri dağılımı, normal dağılımdan farklı ise bu yöntemlerin yetersiz kalacağı açıktır. Ayrıca, standart sınıflandırma teknikleri; sınıflar için yeterli miktarda örneklem verisi (training data) bulunmadığı zaman iyi sonuçlar vermemekte, farklı yaklaşımlar denenerek bu olumsuzluk giderilmeye çalışılmaktadır. Sınırlı miktarda olan ve/veya ilgili sınıfı temsil etme özelliği yeterli olmayan veri setleri için tatmin edici sonuçlar/ doğruluklar elde etmek, klasik yöntemlerle çoğu zaman mümkün olmamaktadır.

Konuyu çarpıcı bir örnekle açıklamak gerekirse; En büyük benzerlik (maximum likelihood) sınıflandırma yöntemi, uzaktan algılanmış görüntülerin sınıflandırılmasında kullanılan en yaygın ve bilinen kontrollü sınıflandırma yöntemidir. Bu yöntemin başarısı , her spektral sınıf için dağılım parametrelerinin (ortalama vektör ve kovaryans matrisi) doğru biçimde tahmin edilmesine bağlıdır. Bu da sınıflar için yeterli miktarda örneklem verisinin olmasıyla mümkündür. Bu mümkün olamıyorsa kovaryans matrisi elemanları doğru biçimde tahmin edilemez ve istenen sınıflandırma doğruluklarına da ulaşılamaz. Bu nedenle örneklem veri grubu büyüklüğü sınırlı olduğu zaman kovaryans bilgilerini kullanmayan, yalnızca spektral sınıfların ortalama vektörlerinin kullanımına bağlı olan sınıflandırma algoritmalarına başvurmak gerekir (En küçük uzaklık vb.). Bu da standart olarak kullanılan algoritmaların bile her durumda en iyi çözüm olamayacağı gerçeğini yansıtmaktadır. Eklemek gerekir ki; örneklem veri setinin sahip olduğu özel sınıf olasılık dağılımı karakteristiklerinin belirlenmesi ve ona uygun yöntemin seçilmesi pratik uygulamalarda hızlı ve kesin kurallarla pek mümkün değildir. Anlatılan bu özellikler bir bakıma parametrik yöntemlerin sahip olduğu bazı dezavantajları yansıtmaktadır.

Anılan standart algoritmalar kavramı içinde diskriminant analiz algoritmalarına da değinmek gerekmektedir (en popüler olanı Fischer diskriminant analizidir). Bu algoritmalar, istatistiksel veri analizinde kullanılan yaygın tekniklerdir. Fischer diskriminant analize dayanan non-linear sınıflandırma teknikleri önerilmektedir. Lineer diskriminant analiz yönteminin pratik uygulamalarda yeterince kompleks olmadığı göz önüne alınırsa; Optimum Bayes sınıflandırma yönteminin modellendirilmesinde daha gelişmiş dağılım modelleri kullanarak geliştirilen non-linear sınıflandırma teknikleri de uygulama alanı bulabilmektedir (kernel algoritmaları

vb.). Fischer diskriminant analiz yönteminin teorik “güzelliği” bilinmekle beraber, sınırlı kapasitesi göz önünde bulundurulmalı ve daha genel amaçlı “sınıf ayırabilirlik kriteri” elde edebilecek yaklaşımlar geliştirilmelidir.

Araştırmalar, örnekleme verileri olasılık dağılım diyagramlarının bir hiperelipsoid yardımıyla bile tanımlanamayacak dağılımlar gösterdiğini ortaya çıkarmıştır. Bu nedenle ve yukarıda açıklanan gerekçeler nedeniyle parametrik algoritmaların çelişki ve sınırlamalarını içermeyen yeni sınıflandırma algoritmalarına gereksinim vardır. Sınıf dağılımları hakkında herhangi bir varsayım yapmayan, istatistiksel varsayımlardan kaçınmak için kullanılan bu algoritmalara non-parametrik algoritmalar denilmektedir. Non-parametrik sınıflandırma algoritmalarında sınıf dağılımlarına ilişkin varsayım yapılmaması nedeniyle, örnekleme veri grubunun normal dağılımdan farklı dağılıma sahip olduğu durumlarda bu algoritmalar daha güvenilir ve doğru sonuçlar üretmektedir. Bu anlamıyla parametrik olmayan tekniklerin standart yöntemlerden daha üstün olduğunu söylemek mümkündür.

Non-parametrik algoritmalar olan Yapay Sinir Ağları, hassas bir sınıflandırma tekniği olarak, yaygın biçimde ve çok çeşitli bilimsel alanlarda kabul gören yeni bir teknik olmuştur. Multispektral görüntülerin sınıflandırılmasında yapay sinir ağları uygulamaları hızla artmaktadır. Klasik istatistiksel sınıflandırma tekniklerinde her veri türü kullanımının mümkün olmaması ve farklı türlerdeki verileri (multitemporal, multisensor, yardımcı veriler v.b.) kullanma isteği de bu algoritmalara olan ilginin artmasına yol açmıştır.

Parametrik olmayan yapısı nedeniyle yapay sinir ağlarının standart sınıflandırma tekniklerinden daha üstün olduğu belirtilmişti. Bu noktada, ayrıca multispektral uzayda sınıfları birbirinden ayıran yüzeylerin temel şekillerini (diskriminant fonksiyonu ve karar yüzeyleri) genel anlamıyla irdelemek ve karşılaştırma yapmak (parametrik ve non-parametrik teknikleri) yararlı olacaktır. Günümüzde en çok kullanılan ve bilinen standart sınıflandırma yöntemi olan en büyük benzerlik yöntemi (max. likelihood) ile non-parametrik yöntemlerden yapay sinir ağlarını karşılaştırmak yararlı olabilir. En büyük benzerlik yöntemiyle sınıflandırma işleminde oluşturulan “karar yüzeyleri” quadratik formdadır; yani, parabol, daire veya elips şeklini alırlar. Yapay sinir ağları ise; özellik uzayında yüksek dereceden ve lineer- olmayan karar yüzeyleri oluşturabilme yeteneğine sahiptir. Sözgelimi “ üç- tabakalı sinir ağı yapısı ” sınıflandırma işleminde çok yönlü, esnek ve kompleks karar yüzeyleri oluşturabilir; dolayısıyla diskriminant fonksiyonları istenilen şekli alabilmektedir (Bu ifadenin her sinir ağı türü için geçerli olmadığını vurgulamak gerekir). Buradan, yapay sinir ağları

ile mümkün olabilen yüksek dereceli karar yüzeylerinin, standart sınıflandırma teknikleriyle oluşturulabilecek karar sınırlarından daha kompleks ve doğru ayrılabilirlik kriteri (dolayısıyla daha iyi sınıflandırma doğruluğu) oluşturabileceği sonucuna ulaşılabilir.

Bütün bu avantajlarına ve kapasitesine rağmen Yapay Sinir Ağlarının bazı handikapları da bulunmaktadır: Ağın çalıştırılması (training) için çok fazla zaman gerektirmesi, kullanıcı deneyimi gerekliliği, ağ yapısı geliştirme işinin dolaylı oluşu (bir optimizasyon problemidir), uygun parametre değerleri seçiminin önemli olması v.b. sayılabilir. İşlem zamanının fazlalığına rağmen (uygun öğrenme parametresi kullanılarak zaman azaltılabilir) multispektral sınıflandırma için yapay sinir ağları en uygun ağ mimarisi ve parametre seti kullanıldığı zaman, standart istatistiksel sınıflandırma tekniklerinden daha doğru sonuçlar üretmektedir. Uygun sinir ağı mimarisi ve parametre değerlerinin seçimi (optimizasyon), başarılı bir Yapay Sinir Ağı sınıflandırmasında kilit rol oynar.

Sinir ağlarının kullanımı, kullanıcının sonuç sınıflandırma doğruluğunu doğrudan etkileyebilecek kararlar vermesini gerektirir. Bu kararlardan bir tanesi, spesifik bir problem için optimum sinir ağı yapısının belirlenmesiyle ilgilidir. Ağ mimarisi gerçekten ağın “ genelleştirme ” kapasitesini doğrudan etkilemektedir (Genelleştirmeden kastedilen ağın çalıştırılması bittikten sonra örnek veri seti içinde bulunmayan yeni verileri, doğru biçimde tahmin etme kapasitesidir). Bir sinir ağının “gücü”, yeni verileri ne kadar iyi genelleştirdiğine bağlıdır. Bu aynı zamanda ağın performansını değerlendirmenin ana kriteridir.

Bir ağın genelleştirme kapasitesini arttırmak amacıyla; optimum ağ yapısının saptanabilmesi için ağ büyüklüğünün ve birimlerinin sistemli olarak azaltılması-indirgeme yönünde yaklaşımlar geliştirilmiştir (pruning algorithms). Burada indirgemeden amaç: ağın çözümüne yardımcı olmayan, gereksiz birimlerin atılmasıdır. Ağ istenen çözüme ulaşılan kadar çalıştırdıktan (training) sonra birimler (gizli tabaka birimleri veya iç bağlantılar) çözüme katkıda bulunup/ bulunmadığını tesbit etmek amacıyla analiz edilirler. Genel olarak bu yöntemlerde, ağ indirgemesini gerçekleştirmek için hata fonksiyonunun ikinci dereceden türevlerinin kullanımına dayanan yaklaşımlar geliştirilmiştir. Burada karşılaşılan önemli bir problem, ikinci dereceden türevlerin oluşturduğu Hessian matrisin “aşırı” büyüklükte oluşudur. Bu hem hesaplamaları zorlaştırır, hem de gereken zamanın çok artmasına yol açar. Bu yüzden bu matrisin diagonal olduğu varsayımıyla bazı yaklaşımlar denenmiştir. Hessian matrisin inversinin hesaplanması işleminin ağın

genel alıřtırma iřleminin olduka yavařlaması ve ok daha fazla hafızaya gereksinim duyması; sınıflandırma iřlemlerinde bu yntemlerin kullanımının pratik ve kolay olmayacağıının gstergesi sayılabilir.

Genel olarak sinir ağı uygulamalarında karşılaşılan glklerden birisi, uygun mimarinin oluřturulması konusundadır. Herhangi bir 'ğrenme' problemi iin ok sayıda muhtemel ağı yapısı kurulabilirse de bu yapıların yalnızca kk bir blm istenen sonuları verebilir. Bu nedenle yukarda anılan indirgeme yntemlerinden bařka, ağı yapılandırma, apraz doėrulama (verilere dayalı yntemler) ve bilgi bazlı ltler v.b. otomatik sinir ağı yapısı seimi gerekleřtirebilen teknikler nerilmiřtir.

Gnmzde en ok kullanılan sinir ağı sınıflandırma yntemi "ok tabakalı algılayıcı sinir ağı" (multilayer perceptron) olup geniř biimde analiz edilmiř ve eřitli ğrenme algoritmaları geliřtirilmiřtir. Bu tr aėlar genellikle hata 'geriyayılma' (backpropagation) algoritması ile alıřtırılır. Bu algoritma hesaplanması kolay olmasına ve sinir ağı topluluėunda yaygın biimde kullanılmasına raėmen; uzun srede zme ulařması ve hata yzeyinde kimi zaman yerel minimum deėerine ulařması (yakalanması) nedeniyle bazı dezavantajlara sahiptir. Bununla birlikte, bir gradyen arama tekniėi olarak, byk veri grupları zerinde alıřması iyi sonu verirken, sınırlı byklkteki veri zerinde "en iyi zm" olarak dřnlemez. Bu anlamıyla daha hızlı zm saėlayacak ve sz konusu sakıncaları/ sınırlamaları iermeyen teknikler kullanılmalıdır.

Bu anlamda tez kapsamı iinde hızlı zm saėlayabilecek, yerel minimuma yakınsamayan, sayısal kesinliėe sahip ve az sayıda kullanıcı- tanımlı giriř parametresi ieren yeni bir teknik nerilmiřtir. Optimizasyonun elde edilmesinde Levenberg- Marquardt yntemine dayanan bir yaklařım uygulanmıřtır (Levenberg- Marquardt yntemi yalnızca yapay sinir ağı alanında deėil, sayısal analizde de kullanılan genel bir optimizasyon tekniėidir). Uygulama sonuları nerilen yntemin klasik algoritmalara gre hız, kapasite ve performans ynnden stnlėn kanıtlamıřtır.

Yapay sinir aėları ile ilgili olarak, zerinde durulması gereken nemli bir eksiklik; sinir ağı doėruluėunun tahmin edilmesi, tahmin ynteminin oluřturulma biimi ve pratik ve uygulanabilir bir "gvenlik lt" nn tanımlanması konusundadır. Bu konuda sistematik alıřmaların az sayıda yapılmıř olması řařırtıcıdır. Gnmzde konuyla ilgili gncelliėini koruyan sınırlı sayıda alıřma yayınlanmıřtır. Sinir aėlarında uygun yapı ve parametre seimi ile " genelleřtirme" doėruluėunun

arttırılabileceği bilinmekle beraber, ağın duyarlılığında elde edilebilecek bir artışın önceden (a priori) kestirilebildiği sistematik bir yöntem bulunmamaktadır. Ama yine de fonksiyonel ilişkilerin tahmin edilmesinde elverişli olabilecek bir ağ için, doğruluk değerini belirlemenin bir yolu da olmak zorundadır. Güvenlik tahmin değerlerinin elde edilmesi için farklı yöntemler önerilebilir (burada 'güven' terimini sınıflandırmanın doğru olma olasılığı ile ilişkilendirmek gerekir). Tez kapsamında sinir ağı doğruluk güven tahmini için, istatistik teorisine dayalı olarak, tahmin değerlerinin güven aralıklarının oluşturulmasında binom olasılık dağılımından yararlanılan yeni ve kullanışlı bir metodoloji geliştirilmiştir. Bu yaklaşımda örnekleme veri grubunun büyüklüğüne bağlı olarak Poisson dağılımından da yararlanılmaktadır. Bu teknik yardımıyla, çalıştırılan bir sinir ağının önceden belirlenen bir hata sınırı içinde ve güven düzeyinde ağın sonuç değerlerini kullanarak istatistiksel anlamda ağın kabul edilebilirliği üzerinde bir test ölçütü oluşturulmaktadır. Bu amaçla önce örnekleme veri grubu üzerinde rastgele (random) ölçü grupları seçilmekte, bu grubun ağ sonuçları önceden belirlenmiş hata sınırı değeriyle karşılaştırılarak elde edilecek farklılıkların istatistiksel anlamda güven aralıkları hesaplanmakta ve sonuçta bu değerlerin istenen güven düzeyinde olup olmadığına bakılarak sinir ağı modelinin kabul edilebilirliği test edilmektedir. Böylelikle sinir ağı sınıflandırma doğruluğunun güvenlik tahmin değeri için yeni bir yöntem geliştirilmiş olmaktadır.

Bu tez çalışmasında ele alınan konular, genel olarak içerik/ kapsam yönünden değerlendirildiğinde aşağıdaki amaçları hedeflediği tespit edilebilir:

- parametrik sınıflandırma algoritmaları (standart istatistik yöntemler) ile yapay sinir ağları kullanılarak yapılan sınıflandırmaların sonuçlarını karşılaştırmak,
- farklı yapıdaki sinir ağlarının performanslarını ve bunların sınıflandırma doğruluğuna olan etkilerini incelemek,
- uzaktan algılama verilerinin görüntü sınıflandırmasında kullanılabilecek bir yapay sinir ağı algoritması geliştirmek ve bununla ilgili bir yazılım tasarlamak (HYSA),
- çalıştırılan sinir ağlarının sonuç doğruluklarının güvenliğinin tahmin edilmesi için istatistik olarak bir algoritma geliştirmek, bunun yazılımını tasarlamak ve uygulamak,
- standart sınıflandırma algoritmaları ile birlikte kullanım alanı bulan bazı sınıflandırma tekniklerinin performanslarını incelemek ve karşılaştırma yapmak,

olarak özetlenebilir. Sonuç olarak yapay sinir ağıları, uzaktan algılamada görüntü sınıflandırması için klasik yöntemlere iyi ve etkin bir alternatif olarak standart bir araç olma yolundadır. Yapay sinir ağıları, görüntü sınıflandırmasına yeni kuramsal ve pratik açılımlar getiren, gelişmiş ve yetkin bir teknoloji olarak değerlendirilmelidir.



2. GÖRÜNTÜ SINIFLANDIRMASINDA YAPAY SİNİR AĞLARI KULLANIMI ÜZERİNE BİR LİTERATÜR ARAŞTIRMASI

1980'li yılların ortalarından beri Yapay Sinir Ağları algoritmalarının çok çeşitli bilimsel disiplinlerdeki uygulamalarında hızlı bir artış görülmektedir. Uzaktan Algılamadaki kullanımı ise görece yeni sayılabilir. Buna karşın son birkaç yıl içinde yayın sayısında artış gözlenmektedir. Bu uygulamaların çoğunda geri-yayılma (backpropagation) algoritması ile çalıştırılan " çok tabakalı algılayıcı sinir ağı" (multilayer perceptron : MLP) kullanılmıştır. Bu uygulamalarda çok çeşitli uzaktan algılama verisi (yüksek optik çözünürlüklü (Landsat, SPOT v.b.) ve düşük çözünürlüklü (NOAA- AVHRR) multispektral görüntüleme, spektrometreler (AVIRIS), yapay açıklıklı radar verileri vb.) üzerinde analizler yapılmıştır. İlk çalışmalarda tek bir veri kaynağı kullanılmasına rağmen, son çalışmalarda ileri arazi örtüsü sınıflandırması için çok- kaynaklı verilerin tümleşik analizinde sinir ağlarının ne kadar esnek olabileceği gösterilmiştir.

Uzaktan algılama verilerinin (görüntü) analizinde yapay sinir ağları ile ilgili olarak literatürdeki ilk yayınlardan biri Key ve diğ. (1989) tarafından yapılmıştır. 5- kanallı AVHRR verisi ile 2- kanallı SMMR radyometre verisinin birleşik (merge) görüntüsünün bulut sınıflarına ayrılması için sinir ağı sınıflandırma yöntemi kullanılmıştır. Elde edilen sonuçlar en büyük benzerlik yöntemi ile karşılaştırılmış, olumlu ve olumsuz tarafları tartışılmıştır.

Howald (1989), Landsat TM verilerinin sınıflandırılması için üç tabakalı sinir ağını kullanmış ve enbüyük benzerlik yöntemine oranla biraz daha iyi sınıflandırma doğruluğu elde etmiştir. Aynı sinir ağı mimarisi Hepner ve diğ. (1990) tarafından kullanılmış ve aynı örnekleme veri seti için sinir ağının klasik sınıflandırma yöntemlerinden daha iyi sonuç verdiği gözlenmiştir. Bu çalışmalarda farklı ağ mimarileri denenmiş olup, MLP sinir ağlarının en iyi sonucu verdiği görülmüştür.


Gualtieri ve Withers (1988) ve Kamgar ve diğ. (1990), uzaktan algılamada sinir ağları uygulamaları ile ilgili ikinci önemli uygulamayı açıklamaktadırlar: multispektral verilerin kümelendirilmesi (clustering) yöntemi. Bu çalışmalarda çok yüksek boyutlu

görsütölemede (görsütöleyici spektrometreler) kümeleme yönteminin potansiyeli gösterilmiştir.

Wilkinson ve diğ. (1992), Kuzey Atlantik Okyanusunun NOAA-AVHRR görsütöleri üzerinde bulut alanı modellerinin kontrolsüz kümelendirme işlemini gerçekleştirerek için, ünlü Kohonen' in " otomatik-organize dönüştümü (self-organising map) " sinir ağını kullanmıştır. Sinir ağıları kullanılarak bulut sınıflandırması yapılan diğör bir uygulama Lee ve diğ. (1990)' ye aittir. Tek kanallı Landsat MSS görsütüsü (görünür bölgede) kullanarak, çok yüksek bulut tanıma doğrulukları elde etmiştir. Üç tabakalı sinir ağı, en yakın komşuluk ve lineer diskriminant analiz yöntemleri kullanılarak karşılaştırmalar yapılmıştır. Tüm bu çalışmalar içinden 4- tabakalı sinir ağının en yüksek bulut sınıflandırma doğruluğunu verdiği belirtilmiştir.

Bir diğör önemli ve ilginç çalışmada Benediktson ve diğ. (1990), Landsat MSS görsütüsü ile yükseklik, eğim, görünüm gibi yardımcı topoğrafik verilerden oluşan çok- kaynaklı (multisource) verinin sınıflandırılmasında 3- tabakalı sinir ağını kullanmıştır. Sonuçlar istatistik tekniklerle karşılaştırdığında sinir ağlarının daha iyi olabileceğini belirtmişlerdir. Bu çalışmada ayrıca giriş verilerinin alternatif veri gösterimi (kodlama tekniğini) kullanılmış ve incelenmiştir.

Kanellopoulos ve diğ. (1992), çok- zamanlı SPOT multispektral verilerinin arazi kullanım sınıflarına (20 sınıf) bölünmesi için 4- tabakalı sinir ağını kullanmıştır. Sınıflandırmanın kompleksliliği yüzünden daha büyük sinir ağı mimarisi gerekli olduğu görölmüş ve çözüm zamanı da paralel olarak artmıştır. Kanellopoulos ve diğ. (1991) sınıflandırma için hiyerarşik sinir ağı yaklaşımını kullanmıştır (Şekil 2.1). Bir tane üst seviyede ve altta spesifik sınıfları sınıflandırmak için ikinci seviyede iki ağ tasarımı olmak üzere toplam üç ağ tasarımı yapılmıştır.




Şekil 2.1- Kanellopoulos'un hiyerarşik sinir ağı mimarisi (1991)

Sınıflandırma doğruluğunda belirgin bir artış görülmemekle beraber daha basit (yalın) seviyeden sinir ağı yapısı kullanılma olanağı nedeniyle işlem zamanı yarıya inmiştir. Hiyerarşik ağlar başka araştırmacılar tarafından da kullanılmıştır.

Chen ve diğ. (1995) multispektral SPOT görüntülerinin sınıflandırılması için “ Kalman Filtreleme ” tekniğini kullanarak bir dinamik- öğrenme sinir ağını tasarlamışlardır. Sonuçta yüksek sınıflandırma doğruluklarına ulaşılmıştır. Buna ek olarak geriyayılma algoritması ile çalıştırılan bir sinir ağı ile dinamik öğrenme ağı kıyaslandığında işlem zamanında anlamlı bir azalma görülmüştür.

Foody (1995), uzaktan algılama verileri (SAR görüntüleri) ile yardımcı verileri bir GIS ortamında bütünleştirerek, bu verilerin fuzzy (bulanık) sınıflandırma sonuçlarını elde etmek için yapay sinir ağını kullanmıştır. İlk olarak arazi sınıfları hem sinir ağlarından hem de diskriminant analiz sınıflandırma yöntemleri ile elde edilmiş, sonuçta sinir ağı ile daha yüksek sınıflandırma doğruluğuna ulaşılmıştır. Yardımcı verilerin eklenmesiyle oluşturulan sinir ağı toplam sınıflandırma doğruluğunu arttırmıştır. Ayrıca sınıfların öncül olasılıklarının ilişkilendirilmesiyle her iki yöntemde de doğruluk artışı olduğu belirlenmiştir.

Paola ve Schowengerdt (1994,1995) Landsat TM görüntülerinden kentsel arazi kullanımının sınıflandırılması için, geriyayılma algoritması ile çalıştırılan sinir ağları ve enbüyük benzerlik sınıflandırma yöntemini kullanmış ve detaylı karşılaştırmalar yapmıştır. Toplam sınıflandırma doğrulukları için birçok durumda benzer sonuçlar elde edilmesine rağmen, araştırmacılar iki yöntem arasındaki farkı daha iyi açıklayabilmek için 2- boyutlu karar yüzeyi çizimlerini kullanmışlardır. Benzer görsel teknikler bağımsız olarak Fierens ve diğ. (1994) ve Wilkinson ve diğ. (1995) tarafından da geliştirilmiştir. Wilkinson sinir ağı ile istatistik sınıflandırma yöntemlerinin integrasyonunu kullanmayı denemiştir. Bu yöntemde sinir ağı ve istatistik sınıflandırma yöntemlerinin paralel kullanımını takiben belirsiz nitelikteki örneklerin işlenebilmesi için ikinci bir sinir ağı kullanılmıştır (Şekil 2.2). Bütünleşik (entegre) yöntem kullanımının toplam sınıflandırma doğruluğu üzerinde dikkate değer bir artışa yol açtığı gözlenmiştir.



Şekil 2.2- Wilkinson'un Bütünleşik Sınıflandırma Prosedürü (1995)

Diğer ilginç bir araştırmada Benediktson ve diğ. (1995), çok yüksek boyutlu AVIRIS (Airborne Visible- Infrared Imaging Spectrometer) spektrometre verisinin analizinde sinir ağı ve istatistik yöntemleri uygulamıştır. Bu çalışmada ilk kez “ karar sınırı ile özellik belirleme “ (decision boundary feature extraction) yöntemi kullanılmıştır. Bu yöntemle, veriler içindeki en önemli özelliklerin saptanması ve AVIRIS verilerinin boyut sayısının azaltılmasında yapay sinir ağları kullanımının önemi vurgulanmıştır.

Uzaktan algılanmış görüntülerin sınıflandırılmasında sinir ağları kullanımı üzerinde mükemmel bir çalışma da Paola ve Schowengerdt (1995) tarafından yapılmıştır. Bu iki araştırmacı çalışmalarında, geri yayılma algoritması ile çalıştırılan sinir ağlarına genel bir bakış / çerçeve oluşturmuş ve sınıflandırma işleminin tüm unsurlarını (giriş verilerinin ön-işlemesi, sinir ağı mimarisi ve çalıştırma algoritması, sonuç sınıfların elde edilmesi, kodlama tekniği, klasik sınıflandırma teknikleriyle ilgili karşılaştırmalar, ve ayrıntılı incelemeler vb.) ortaya koymuşlardır.

Çok tabakalı algılayıcı sinir ağları (MLP)'nin uygulamadaki temel zorluklarından birisi; belli bir problem için optimum ağ mimarisinin (yapı) seçimi konusundadır. MLP ağ yapısının seçimi; ağ içindeki tabakaların sayısı, her bir tabakadaki birimler (düğüm), düğümler arasındaki iç-bağlantılar, ve diğer parametrelerin seçimi ile ilişkilidir. Genel olarak herhangi bir “öğrenme” problemi için çok sayıda olası ağ mimarisi kurulması mümkündür, ancak bu yapıların yalnızca bir alt grubu iyi performans verebilir. Bu nedenle MLP ağ mimarisi seçimini otomatik olarak gerçekleştiren çok sayıda yöntem önerilmiş ve bu konuda çok çaba sarfedilmiştir. Bu yöntemler arasında ağ indirgeme (pruning), ağ yapılandırma, çapraz doğrulama

(cross validation) ve bilgi bazlı kriterler (MDL :Minimum Distance Length vb.) gibi teknikler önerilmiştir (Kearns, 1997; Bartlett, 1997). Mimari seçim stratejilerine ek olarak, ağırlık yok etme, işlemi durdurma ve Bayes teknikleri gibi ayarlama (regularization) yöntemleri de bulunmaktadır.

Ağ indirgeme yöntemleri (pruning methods) genel olarak diğer yaklaşımlardan daha çok araştırma konusu olmuştur ve halen gelişme safhasındadır. Burada indirgemedeki kasıt, çözülmüş bir ağın çözüm için gerekli olmayan (çözüme katkısı olmayan) birimlerinin belirlenmesi ve ayıklanması işlemidir. Bir ağ örnekleme veri seti kullanılarak istenen doğruluğa ulaşmaya değin çalıştırıldıktan sonra, birimler (gizli tabaka düğümleri veya bağlantılar) çözüme yardımcı olup olmadıklarını belirlemek amacıyla analiz edilirler. Gerekli olmayan birimlerin belirlenmesi için genel olarak bir tür duyarlılık analizi (hata fonksiyonunun kısmi türevleri) yapılır. Dreyer (1993) bu konudaki önemli çalışmasında, ağın sadeleştirilmesi için en az öneme sahip gizli birimlerin ayıklanmasında hata fonksiyonunun birinci dereceden kısmi türevlerini kullanmıştır. Doğruluk gelişiminde kısmi bir artış görülmektedir. İndirgeme algoritmalarında en çok kullanılan üç yöntem : büyüklüğe bağlı indirgeme yöntemi, optimum brain damage ve optimum brain surgeon (şimdiye kadar kullanılan en sofistike algoritma) 'dır (Hassibi ve diğ., 1993).

Büyüklüğe bağlı algoritma en basit indirgeme yöntemidir; ağın performansı üzerinde en az etkiye sahip büyüklük (ağırlık, bağlantı.. vb.) değerinin atılması, dolayısıyla kaldırıldığı zaman işlem hatası üzerinde etkisi minimum olan büyüklük değerinin belirlenmesi yöntemidir.

Optimum Brain Damage indirgeme algoritması, Le Cun ve diğ. (1990) tarafından ortaya atılmış olup hata fonksiyonunun ikinci dereceden türevlerine dayanmaktadır. Bu yöntemde amaç; silindiği zaman ağ içindeki hatanın en az artışı ile sonuçlanacak biçimde ağırlıkların iteratif olarak silinmesidir. Bağlantının tahmininde en önemli problem Hessian matrisin boyutudur. Matrisin çözümü gerçekten zaman alıcıdır ve bu nedenle matrisin diagonal olduğu varsayılır. Buna karşıt olarak, Hassibi ve diğ. (1993) bir çok problemde Hessian matrisin non- diagonal olduğunu ileri sürerek bu yöntemin yanlış ağırlıkları silebileceğini öne sürmüşlerdir.

Optimal Brain Surgeon yöntemi aynı teorik yaklaşıma sahiptir, farkı; Hessian matrisle ilgili herhangi bir varsayımda bulunmamasıdır. Daha kesin ve kompleks oluşunun nedeni budur. Bu yöntemin diğer iki yöntemden üstün olduğu ileri sürülmektedir (Stepniewski ve diğ.,1998; Kavzoglu ve diğ., 1998). Bu yöntemde de

en büyük sorun Hessian matrisin inversinin alınması konusundadır ve oldukça yavaş olup daha fazla bellek ihtiyacı duymaktadır. Anılan yöntemler henüz gelişme aşamasını tamamlamış değildir, yapay sinir ağı öğrenme işleminin zaten zaman alıcı olması, gereken zamanın çok artmasına neden olmakta ve öğrenme işlemini yavaşlatarak uygulamayı zorlaştırmaktadır.

Burada bir noktaya dikkat çekmekte yarar vardır: “Optimum ağ yapısı” ile kastedilen kavram nedir? Bu ifade; “örnekleme veri grubunda ağır basan fonksiyonu temsil etme yeteneğinde olan en basit ağ yapısı” olarak tanımlanabileceği gibi, daha yaygın bir düşünce ile “sinir ağı işletildikten sonra en iyi sonuç veren ağ yapısı” olarak da tanımlanmakta ve buna göre yöntemler değerlendirilmektedir. Bu noktada; tanımlanan ifadelerde esas alınan ölçütün (kriter) her ikisinin de önemli olduğu, bunlardan yalnızca birine bağlı kalarak geliştirilecek bir yöntemin yetersiz kalabileceği göz önünde bulundurulmalıdır. Çoğu uygulamada bu ölçütlerin birbiriyle iç içe ve birbirini tamamlayan nitelikte olduğu; ayrıca ağ için kurulan “algoritma”nın da belirleyici ve önemli olduğu unutulmamalıdır.

Otomatik uygun ağ mimarisi seçimi için sık kullanılan bir yöntem çapraz doğrulamadır. Yöntemin avantajı olarak; hangi mimarinin en uygun olduğunu belirlemek için, kullanıcı müdahalesine gerek olmaksızın ve herhangi bir parametre ayarlaması yapılmaksızın sadece verilere bağlı kalınması (data driven) gösterilmektedir. Bu yöntem kullanıldığı zaman rastgele mimari seçiminden biraz daha iyi sonuç alınabilmektedir (Prechelt, 1998). Genel üstünlüklerinden biri ise; kullanıcıyı fazla sayıda olan ve optimum olmayan yapı seçme olasılığından kurtarması söylenebilmektedir. Buna karşın, bu teknikle model (benzek) seçim stratejisinde hesaplama işlemlerinin arttığı gözlenebilmektedir. Ayrıca, genel olarak test edilen model sayısı arttıkça, çapraz doğrulamanın en uygun modeli seçme işleminde başarısız olma olasılığı artmaktadır. Ayrıca belirtmek gerekirse, bu konuyla ilgili araştırmaların çoğu deneysel niteliktedir (kullanılan veriler açısından), ve az sayıda veri setiyle denenmiştir. Bu nedenle elde edilen sonuçların genel sonuç niteliğinde olduğunu söylemek zordur. Yine de, iki veya daha fazla öğrenme modelinden, hangisinin daha iyi çalıştığını karşılaştırmak (tahmin etmek) için bu yöntemin kullanılabileceğini bilmek gerekir.

MLP sinir ağı ile sınıflandırma işlemlerinde genel olarak karşılaşılan bir problem, sınıfların (tek tek) öncül olasılıkları (prior probabilities) ile ilgilidir. Eğer sınıflar arasında her bir sınıfa ilişkin deneme örnekleri sayısı anlamlı biçimde değişiyorsa, bazı durumlarda nadir olan sınıfların sinir ağı ile öğrenilmesi zorlaşabilmektedir

(Lawrence ve diğ., 1997). Böyle bir pratik deneyim teorik sonuçlarla uyuşmamaktadır, zira MLP sinir ağıları Bayes soncul (a posteriori) olasılıkları, öncül sınıf olasılıklarından bağımsız biçimde tahmin edebilmektedir. Teorik ve pratik sonuçlar arasındaki farkın nedeni teoride yapılan 'varsayımlar'dan kaynaklanmaktadır. Bayes soncul olasılıkların doğru biçimde kestirilebilmesi için; ağ yeterince büyük olmalı, çalıştırma işlemi global minimum değerine yakınsamalı ve test veri grubunun öncül sınıf olasılıkları işlem veri grubu içinde doğru biçimde temsil edilebilmelidir. Bu nedenle pratik uygulamaların çoğunda MLP çalıştırma mekanizmaları optimum çözümleri sağlamamaktadır (Yaeger ve diğ., 1997).

Sözkonusu problemi aşmak için sınıf bazında uygulanan bir tür "ölçeklendirme" yöntemi önerilmiş ve uygulanmıştır (Lawrence ve diğ., 1998). Bu yöntemlerde sınıf bazında ölçeklendirme işlemi, öncül sınıf olasılıklarına göre ağırlık güncellemeleri yapılması şeklinde olabildiği gibi (öncül ölçeklendirme), sınıflara ait olasılık modelleriyle ilgili ağırlık güncellemelerine uygulanacak ölçek faktörü seçimi şeklinde (olasılıklı örnekleme) de olabilmektedir. Pratikte belli bir sınıflandırma işlemi için sinir ağı çalıştırma özellikleri ele alınırsa, tahmin edilen sınıf olasılıklarının ölçeklendirilmesi toplam sınıflandırma hatası üzerinde bir iyileştirme- gelişme sağlayabilir. Ancak ölçeklendirme işlemi bazı durumlarda ağırlık güncelleme değerlerinin büyümesine, dolayısıyla öğrenme oranının seçimine dolaylı olarak etki yapabilmekte, ayrıca kullanılan metodun özelliklerinin belirlenmesi de zorlaştırmaktadır.

Model (pattern) sınıflandırma, özellik uzayının çok sayıda karar yüzeyi ile bölünmesi (ayrılması) işlemidir. Sınıflar arasında bir örtüşme olduğu zaman, sınıflandırma hatalarının olasılığını minimum yapmak gerekir. Hataların minimize edilmesi için kullanılan yaygın bir yaklaşım Bayes karar kuralıdır. Ancak Bayes yöntemi de sınıfa-bağlı şartlı olasılık dağılımının doğru biçimde tahmin edilmesini gerektirir. Bu nedenle, olasılık dağılım fonksiyonunun kestirilmesinde yarı-parametrik yöntemlerin uygulaması ilgi çekmeye başlamıştır. Gauss Karışım Modelleri, olasılık dağılım fonksiyonlarının tahmin edilmesinde kullanılan yarı-parametrik tekniklerden biridir (Yiu, 1999). Bu dağılım modelleri, rastlantısal nitelikteki dağılımların karakteristiklerini modellendirebilme kapasitesine sahiptir ve geniş biçimde uygulama alanı bulmuştur. Aslında MLP sinir ağlarının model sınıflandırmada popüler olmasının bir nedeni de, MLP sinir ağı sonuçlarının Bayes soncul olasılıklarının tahmin değerlerine yakın olmasıdır. Böylelikle sinir ağları Bayes sınıflandırma yöntemleriyle sıkça ilişkilendirilmektedir. Benzer biçimde olasılık karar-

bazı sinir ağı modelleri önerilmektedir (Lin ve diğ., 1997). Gerçekte bu sinir ağı modellerinin genel özelliği, ana fonksiyon olarak Gauss Dağılımını kullanıyor olmalarıdır. Gauss karışım modeli parametrelerinin belirlenmesinde de farklı yaklaşımlar geliştirilmiştir (Mak ve diğ., 1998). Gauss karışım modelleri, sınıflandırma işlemlerinde genel olarak uygulanabilir bir yöntem olmasına rağmen, bazı sınırlamalar da içermektedir. Özellikle belli bir sınıfa ait olmayan verilerin olasılık modellendirilmesinde hatalı sonuçlarla karşılaşılabilir.

MLP sinir ağlarında üzerinde durulan diğer bir konu da hata geriyayılma kuralının çalıştırma (training) tarzı ile ilgilidir. Geriyayılma algoritması ya “toplu olarak” (batch) ya da “sürekli” (continuous) biçimde gerçekleştirilmektedir. Toplu çalıştırmada ağırlıklardaki değişimler bir epok üzerinde biriktirilmekte ve bu değerler bir kez ve sonuçta uygulanmaktadır. Sürekli çalıştırmada ağırlıklardaki değişim/ güncelleme her çalıştırma anından sonra uygulanmaktadır. Bazı araştırmalarda toplu çalıştırmanın sürekli çalıştırmadan daha iyi sonuçlar verdiği ileri sürülmektedir. Buna gerekçe olarak da ağırlık güncellemeleri için gerçek hata gradyeninin iyi bir yaklaşımını kullandığı iddia edilmektedir. Bu hipotez daha çok, küçük boyutlu veri grupları üzerinde yapılan deneysel çalışmalarla desteklenmiştir. Dolayısıyla bu savı genele yaymak doğru değildir (Wilson, 2000). Büyük veri grupları için toplu çalıştırmanın sürekliye göre daha yavaş çözüme ulaşacağı ve pratik olmadığı ileri sürülebilir. Ancak deneme veri grubu büyüklüğü ile işlem yöntemi arasında kesin ve anlaşılabilir kuralların konamamış olması ve buna uygun parametrelerin belirlenmesine yönelik açık önermeler yapılmamış olması bu alandaki eksikliğe işaret etmektedir.

Yapay sinir ağlarında kontrollü öğrenmede bir sınıflandırma yöntemi örnekleme setine (deneme seti) bağlı bir öğrenme algoritması kullanılarak oluşturulmalıdır. Kurulan yöntemin performansı genellikle “genelleştirme doğruluğu veya gerçek doğruluk” değerleriyle ölçülür. Buradaki doğruluk, yöntemin örnekleme seti içinde yer almayan verileri doğru biçimde sınıflandırma olasılığıdır. Ancak gerçek doğruluk değeri, pratikte sınıflandırma yöntemini test edebilmek için istenilen büyüklükte ve bağımsız bir veri seti her zaman var olamayacağından dolayı doğrudan elde edilemez. Bunun yerine elde mevcut olan küçük (sınırlı) veri grubuna dayalı olarak gerçek doğruluk tahmini yapılır. Gerçek doğruluğun kestirilebilmesi için kullanılan tipik bir strateji, orijinal veri grubunu iki alt gruba bölmektir: örnekleme (deneme) seti ve test seti şeklinde. Örnekleme seti sınıflandırma algoritmasını çalıştırmak için kullanılırken, test seti sınıflandırma yönteminin doğruluk tahmini için kullanılır. Bu

işlem genellikle tekrarlı olarak uygulanır (veri seti rastgele kısmi bölümlere ayrılarak) ve ortalaması gerçek doğruluğun bir tahminini verir. Otomatik (machine) öğrenme araştırmalarında çok çeşitli doğruluk tahmin yöntemleri önerilmiştir (Weiss, 1994; Kohavi, 1995; Efron vd.,1993). Bunlar arasında en çok kullanılanlar; standart test/ deneme yöntemi, bootstrap ve çapraz doğrulama (cross validation) yöntemidir.

Gerçek doğruluğun kestirilmesinde güvenilir bir yöntemin kurulması, bir sınıflandırma yöntemi için önemlidir. Sınıflandırma yöntemlerinin performansını ölçmek için kullanılan en yaygın parametre onun gerçek doğruluğu olup orijinal veri setine bağlı olarak tahmin edilmek zorundadır. Veri kaynaklarının sınırlı oluşu ve veri toplamanın pahalı oluşu ve dolayısıyla, orijinal veri setinin büyüklüğünün (boyut) genellikle küçük olması nedeniyle genelde izlenen yol, küçük veri grubuna göre gerçek doğruluğun tahmininin yapılmasıdır. Tahmin edilen doğruluk gerçek doğruluktan yüksek varyans (veya yüksek bias) yüzünden sapmaktadır. Bu bağlamda yapılan kestirimin kalitesi büyük oranda uygulanan yöntemle bağlıdır.

Standart test etme yönteminde orijinal veri grubu iki ayrı altgruba bölünür : Bu altgruplardan bir tanesi deneme seti, diğeri test seti olarak doğruluk değerlendirmesinde kullanılır. Bu işlem bir çok kez tekrarlanır, her defasında veri setinin rastgele bir bölümü seçilmektedir. İterasyonların ortalaması alınarak da gerçek doğruluk değerinin tahmin değeri elde edilmiş olur.

Bootstrap yöntemi istatistikte yaygın biçimde kullanılmakta olan bir yöntem olup, bu yöntemde orijinal veri seti içinde, yeniden- örnekleme tekniği kullanılarak belirlenen sayıda altgrup yaratılmaktadır.

Diğer yöntem, otomatik uygun ağ mimarisi seçimi için de kullanılan yöntem olarak tanıttığımız çapraz doğrulamadır. Çapraz doğrulama yönteminde, bir veri seti öncelikle eşit büyüklükte ve belli sayıda rastgele ve ayrık altgruplara ayrılır. Her altgrup sırayla test seti olarak ve geriye kalan altgrup da deneme seti (örnekleme seti) olarak ele alınır. Böylece sınıflandırma yöntemi için deneme seti kullanılırken doğruluk için de test seti kullanılır. Bu işlem her defasında farklı bir altgrup test seti olarak ele alınıp istenen sayıda tekrarlanır. Bu yöntemde de gerçek doğruluk altgrupların ortalaması alınarak belirlenir. Çapraz doğrulamanın ayırdedici özelliği tüm test setinin bağımsız olması ve böylelikle orijinal deneme seti içindeki her “durumun” yalnızca bir defa test edilmesidir. Buna karşın yukarıda anlatılan iki yöntemde bazı durumlar birçok kez test edilirken, bazen hiç test edilmemektedir.

Çapraz doğrulama yönteminin bazı varyasyonlarına da rastlanılmaktadır. Bunlardan biri "katmanlı yapıda çapraz doğrulama"dır.

Yakın zamanda tartışılan ilginç ve güncel bir konu, geriyayılma algoritması kullanan sinir ağlarında karşılaşılmaması muhtemel aşırı-uyuma (overfitting) problemi ve onun genelleştirmeyle olan ilişkisidir (Caruana ve diğ., 2000). Geriyayılma algoritması kullanan ağlarda genel inanış, fazla (aşırı) gizli birim (nöron) kullanımının iyi genelleştirme yapamadığı yolundadır. Fazla kapasiteye (birim) sahip sinir ağları geriyayılma algoritması ile çalıştırıldığında ve erken- durdurma (early stopping) fonksiyonu kullanıldığında iyi genelleştirme yapabildiği ileri sürülmektedir. Buna ek olarak fazla birime sahip MLP ağlarında beklenildiği gibi aşırı-uyuma (overfitting) problemi gözlenmemiştir. Buna gerekçe olarak, aşırı uyuma probleminin hata yüzeyi modelinin farklı bölgelerinde anlamlı derecede değişebilmesini göstermişlerdir. Fazla birime sahip ağ modeli aslında hata yüzeyinin yüksek non-lineariteye sahip bölgelerinde daha iyi uyum göstermektedir. Geriyayılma algoritması da düşük non-lineariteye sahip bölgelerde aşırı –uyuma problemi ile karşılaşmamaktadır (Wolpert, 1997). Gerçekte, bir sinir ağı geriyayılma algoritması ile çalıştırıldığı zaman, genelleştirmenin fazla birim kapasitesine duyarlı olmaması şaşırtıcıdır. Ne varki bu bulguya ulaşmak için yapılan çalışmaların çoğu deneysel nitelikteki sonuçlardan yararlanmıştır.

Ağ üzerindeki bilginin akışı ile ilgili olarak farklı ağ tipi ve parametreleri tanımlanmıştır. Sınırlı doymuş sinir ağları (Constraint Satisfaction Networks) ağırlık bilgisini dış kaynaklardan ve diğer birimlerden (düğüm, nöron) alan birimleri içeren ağlardır. Sırasıyla kendi komşularını etkileyecek şekilde bilginin tüm ağ boyunca yayılmasını sağlayan bir " yumuşatma (gevşeme, rahatlatma) işlemi (relaxation process) " düğümlerin etkinliğini sağlar. Yumuşatma oranının duyarlı bir parametre olup olmadığı açık bir sorudur. Bu oranın bilgi akışını nasıl ve ne derecede etkilediği merak konusudur. Bu oran küçük kaldığı sürece ağ boyunca bilginin yayılma kabiliyetini etkilemediği öne sürülmektedir (Wilson ve diğ., 2000; Zeng, 1999). Bu konuda ilerisi için araştırılması gereken konu, yumuşatma oranının ağ üzerindeki bilgi akışına olan etkisinin tam olarak belirlenebilmesi için analitik formülasyonların ve kanıtların türetilmesidir. Bu konuda halihazırda var olan boşluk doldurulmamıştır.

Yapay sinir ağlarının performansı üzerine yapılan incelemeler dikkat çekicidir. Sinir ağı simülasyonlarının performansı, genellikle farklı başlangıç şartlarıyla (ağırlıklar, vb. gibi) çalıştırılan ağ simülasyonlarının ortalama ve standart sapma terimleriyle ifade edilir. Fakat bir çok durumda ağ sonuçlarının dağılımı normal dağılıma yaklaşık

olmamakta, simetrik özelliği taşımamakta ve multimodal olabilmektedir. Pratik uygulamalardaki normal dağılım varsayımı, sonuçların yorumlanmasını anlamlı derecede etkileyebileceğinden, gerçek dağılım üzerinde daha fazla bilgi sağlayacak yöntemler önerilmektedir. Non- Gaussian dağılımlar için verilerin temsil edilmesinde daha bilgiye dayalı yöntemler (dağılımın çizimi veya kutulu- çubuklar (box-whiskers) çizimleri, vb.) kullanılması tavsiye edilmektedir (Lawrence ve diğ., 1997). Konuyu açmak için geri yayılma algoritmasını bir optimizasyon tekniği olarak ele alalım. Genel olarak bu gibi teknikler yalnızca hata fonksiyonunun minimum değerini bulmayı garanti ederler. Ele alınan problemin kendisi veya işleme algoritması, global optimum çözümü bulmayı güçleştirdiği zaman, sonuç çözümün kalitesini tahmin etmek de zorlaşır. Bu gibi durumlarda sonuç değerlerin dağılımının her zaman Gauss dağılımına uyması beklenemez ve bu nedenle gerçek dağılımının ne olduğu ile ilgilenmek gerekir. Bu durumda ortalama ve standart sapma değerleri performans değerlendirmesinde yanıltıcı olabileceğinden kullanılmamalıdır. Başka bir deyişle; performans dağılımının normal dağılımda olmama olasılığı, çalışma işleminde bir hata riski oluşturmaktadır. Öyleyse, sinir ağı ve algoritma performansının gerçek yapısını daha doğru yansıtabilecek yöntemler geliştirilmelidir. Bu amaçla performans dağılımlarının tanımlanmasında farklı yollar izlenebilmiştir (median terimi ile minimum ve maximum değerlerin kullanımı, Kolmogorov- Smirnov testi ve görsel inceleme için kutulu- çubuklar çizimleri). (Flexer, 1995). Performans dağılımlarının özelliklerini belirlemek için bu yaklaşımların yararlı olabileceği düşüncesi kabul edilebilirse de, sinir ağı simülasyonlarının sonuç dağılımları, ağı yapısına, veriler ile işlem algoritmasına bağlı olarak büyük oranda değişebileceğinden, en uygun çözüm yaklaşımı kolaylıkla bulunamayacaktır. Pratik bir istatistik çözüm olarak, belirli hallerde kaba hatalı değerlerin (outlier) saptanıp ayıklanmasıyla, normal dağılım yaklaşımını sağlamak mümkün olabilir. Belli bir uygulama için sonuçların dağılımının önceden kestirilmesi mümkün olmayacağına göre, kaba hataların tanımlanması ve ayıklanması için kurulacak strateji, sonuç değerlerin gerçek dağılımının gözlenmesine dayanmalıdır.

Model sınıflandırma uygulamalarında yalnızca sınıflandırma yönteminin performansı değil, aynı zamanda böyle bir yöntemin güvenilirliği ile de ilgilenilir. Belli bir sınıflandırma veri seti içindeki sınıflandırılmamış objelerin, sinir ağı sonuç değerlerine bakarak doğru veya yanlış sınıflandırıldığını belirlemek zordur. Yalnızca iyi biçimde çalıştırılmış sinir ağları, soncul olasılıkları doğru biçimde kestirmeleri koşuluyla güvenilir sonuçlar verebilirler. Buradaki ilginç nokta, kötü biçimde işletilmiş bir sinir ağında da geçerli olabilecek bir " güvenlik ölçüsü " tanımlamaktır.

Öğrenme işlemi tamamlanmış bir sinir ağında, bir obje sınıflandırılacağı zaman kullanıcı, sınıflandırmadaki güvenilirliğin ne olduğunu bilmek isteyecektir. Diskriminant fonksiyonu için toplam hata oranı ile ilgili çok araştırma yapılmışsa da, buradaki amaç belli bir sınıflandırmanın doğru olma olasılığını tahmin etmektir. Sınıflandırmanın güvenliği farklı yöntemler kullanılarak tahmin edilebilir. Bunlardan en çok bilinenler : en yakın komşuluk, Parzen yöntemi ve lojistik yöntemlerdir. Bu yöntemlerden en yakın komşuluk yönteminin daha iyi sonuç verdiği gözlemlenmektedir. Lojistik yöntemin ise uygulama kolaylığı göze çarpmaktadır (Hoekstra ve diğ., 1996).

İleri- itilimli sinir ağları (feedforward neural networks) pratik sınıflandırma ve regresyon problemlerinin çözümünde yaygın biçimde kullanılmaktadır (Tez kapsamında da bu tür sinir ağı yapısı esas alınacaktır). Bu tür uygulamalarda güvenilir ve pratik bir “ güvenlik kestirim ölçüsü ” çok gereklidir. Sinir ağlarında güvenlik kestirim yöntemi olarak kullanılan üç yeni yöntem vardır : En büyük benzerlik, yaklaşık Bayes ve “bootstrap” yöntemi (Edwards ve diğ., 2000). Yapay sinir ağları tahmin yöntemleri çeşitli nedenlerden dolayı “ belirsizliklere ” sahiptir. Bunlara örnekleme veri seti içindeki hatalar veya modelin sınırlı oluşundan kaynaklanan hatalar neden olur. Oluşturulacak tahmin yöntemi her iki hata kaynağını da dikkate almak durumundadır. Örnekleme veri grubu içindeki belirsizlikler veri bozunum (noise) varyansı ile model belirsizliği de model belirsizlik varyansı ile ifade edilmektedir. En büyük benzerlik yönteminde temel dezavantaj, veri bozunum varyansının tahmininde ortaya çıkmaktadır. Bayes yaklaşımında veri bozunum varyansı giriş değerlerinin fonksiyonu şeklinde ele alınarak varyans tahmini yapılmaktadır. Bu yöntem ağırlık uzayında zaman alıcı işlemler yapılmasını gerektirir, bu nedenle pratik uygulamalarda uygun değildir. “ Bootstrap ” yöntemi her iki yöntemden farklıdır. Yaklaşık Bayes en büyük benzerlik yönteminden daha iyi sonuç vermektedir (Hwang ve Ding, 1997).

Yapay sinir ağları ile ilgili olarak, üzerinde durulması gereken önemli bir eksiklik: sinir ağı doğruluğunun kestirimi, tahmin yönteminin oluşturulma biçimi ve pratik ve uygulanabilir bir “güvenlik ölçütü” nün tanımlanması konusundadır. Tez kapsamında sinir ağlarında güven tahmini ile ilgili olarak istatistiksel örnekleme teorisine dayanan bir algoritma geliştirilmiştir. Bu algoritma öğrenme işlemi tamamlanmış bir sinir ağının, kullanıcı –tanımlı bir doğruluk derecesinde elde edilmesini garanti etmektedir. Gerçek sınıflandırma problemlerinde öncül olasılıklar ve örnekleme dağılımı gibi parametreler bilindiği için, güven değerlerinin kestirilmesine gereksinim

vardır. Kantitatif olarak güvenlik kestirim yönteminin kurulması konusunda yukarıda anılan yöntemler olmasına rağmen pratik ve kolay uygulanır bir doğruluk güven kestirimi kurulması konusunda literatürde az sayıda çalışma yapılmış olması şaşırtıcıdır.

Uydu algılama sistemlerinin ilk kuşağına kıyasla son algılayıcılar, birkaç banddan yüzlercesine kadar değişen aralıkta spektral bandlardan oluşan yüksek konumsal çözünürlüklü görüntü verileri sağlamaktadır. En uygun spektral bandların seçimi, uzaktan algılama araştırmacılarının üzerinde inceleme yaptıkları konulardan biridir. Bu konu “ özellik seçimi (feature selection) ” olarak bilinmekte ve geniş biçimde incelenmektedir. Özellik seçimi, korelasyonsuz ve en uygun band kombinasyonunun elde edilmesi için, bandların azaltılması işleminde önemli rol oynar. Yapay sinir ağları sınıflandırmasından önce gerçekleştirilecek özellik seçimi işleminin ağın genelleştirme kapasitesini arttırabileceği belirtilmektedir (Mather ve diğ., 2000). Ne varki bu çalışmalar çok yenidir ve uzaktan algılamada uygun band kombinasyonunun belirlenmesi amaçlı özellik seçiminde kullanılan birçok ayrılabilirlik ölçüsü (Divergence, Bhattacharyya uzaklık, Jeffries-Matusita uzaklık, ...vb.) ile ayrıntılı ve kapsamlı karşılaştırmalar/ sonuçlar içermemektedir.

3. GÖRÜNTÜ SINIFLANDIRMASI ALGORİTMALARI

Uzaktan algılama verilerinin analizi ve yorumlanabilmesi için, model (pattern) sınıflandırma, yapay zeka, bilgisayarlı görüntüleme, görüntü işleme ve istatistik analiz gibi çok çeşitli disiplinlerin teknikleri kullanılmaktadır. Yersel ölçmelerin yüksek maliyetli oluşu ve verilerin gittikçe artan hacmi nedeniyle uzaktan algılama verilerinin otomatik analizi için duyulan gereksinim de paralel olarak artmaktadır. Algılama platformlarının yeni jenerasyonu daha yüksek konumsal çözünürlüklü verilerin elde edilmesini sağlamış olup, uzaktan algılama ürünlerinin daha geniş uygulama alanlarına yayılmasına ve daha sofistike (gelişmiş) otomatik analiz yöntemlerine gereksinim duyulmasına neden olmuştur. Daha genel bir ifadeyle; şu an mevcut olan klasik sınıflandırma teknikleriyle elde edilenden daha fazlasına ihtiyaç vardır.

Geçen on yılda, uzaktan algılama verileri için, ileri sınıflandırma algoritmalarının (istatistiksel, bilgi- tabanlı, yapay sinir ağı, bulanık mantık,...vb.) geliştirilmesi için çok çaba harcanmıştır.

Görüntü sınıflandırması işlemi, görüntü içindeki piksellere (görüntü elemanı) uygun algoritmalar kullanılarak arazideki özel kullanım (örtü) sınıflarını temsil eden etiket bilgilerinin atanması esasına dayanır. Sayısal (digital) görüntü sınıflandırma işleminde ise, bir veya daha fazla spektral band (kanal) içindeki sayısal numaralarla temsil edilen spektral (yansıma) bilgilerinin kullanımı söz konusudur. Sınıflandırılmış bir uzaktan algılama görüntüsüne bir bakıma bir tür sayısal tematik harita gözüyle bakılabilir (Schowengerdt, 1983).

Herhangi bir sınıflandırma işleminde ilk adım, ilgili sınıf özelliklerinin tanımlanmasıdır. Sınıflandırmanın bu yönü, tüm işlemin başarısı için kritiktir ve sınıflandırma analistinin en çok zamanını alan da bu kısımdır. Sınıf özelliklerinin (ortalama vektör, kovaryans matris) tanınabilmesi için örnekleme pikseller grubunun temin edilmesi gerekir. Geleneksel olarak sınıflandırma işlemleri bu noktada iki genel bölümde değerlendirilir: kontrollü (supervised) ve kontrolsüz (unsupervised) sınıflandırma.

Kontrollü sınıflandırma yaklaşımında analist; arazi ölçmeleri, fotoyorumlama, mevcut haritalar ve diğer kaynaklardan elde ettiği öncül bilgileri kullanarak seçeceği örneklerden sınıf özelliklerini tanımaya çalışır. Kontrolsüz sınıflandırmada ise, heterojen piksel örneklerinden özellik vektörlerinin doğal olarak mevcut olan grupları (kümeler) ele alınır ve bu kümelerin görüntü içindeki özellik sınıflarını temsil ettikleri varsayılır. Kontrollü sınıflandırmada örnekleme bölgelerinin 'dış' bilgilerine dayalı olarak sınıf karakteristikleri belirlendikten sonra, pikseller sayısal anlamda en çok 'benzedikleri' spektral sınıflara atanırlar. Kontrolsüz sınıflandırmada ise, spektral sınıflar veri seti içindeki doğal (istatistik) gruplarına/ yapılarına göre kümelere ayrılmaktadır (clustering). Kaç tane grup olacağı ve ayrıca kümeler arasındaki ayrım uzaklığı analist tarafından belirlenmekte ve sonra bilgi sınıflarıyla eşlenmektedir (Örmeci, 1995).

Kontrollü ve kontrolsüz sınıflandırma işlemleri birbirini tamamlayacak niteliktedir; ilki analistin örnekleme bölgesi ile ilgili dış bilgisini, sonraki de verinin doğal yapısı ile ilgili özelliklerini bütünleştirmektedir.

Sınıflandırma işlemlerinde kullanılan algoritmalar genel olarak parametrik ve parametrik olmayan algoritmalar olmak üzere iki ana gruba ayrılmaktadır. Parametrik algoritmalar genellikle özel bir sınıf istatistik dağılımı varsayılarak (normal dağılım) ilgili dağılımın parametrelerini (ortalama vektör, kovaryans matris) tahmin etmeye çalışmaktadır. Klasik sınıflandırma algoritmaları (en küçük uzaklık, enbüyük benzerlik,...vb.) bu gruba dahildir. Buna karşın non- parametrik algoritmalar sınıf dağılımları ile ilgili olarak herhangi bir varsayım yapmamaktadır. Çok çeşitli sınıf dağılımları için bu algoritmaların iyi çalıştığı görüldüğü için bazen " kesin (robust) algoritma " olarak da adlandırılmaktadır. Parametrik olmayan algoritmalar yapay sinir ağlarının bir sınıflandırma yöntemi olarak etkin biçimde kullanımı yaygınlaşmış ve potansiyeli gösterilmiştir.


3.1. Parametrik Sınıflandırma Algoritmaları ve Bazı Dezavantajlar

Parametrik sınıflandırma algoritmaları sınıflar arasındaki karar sınırlarını (decision boundary) oluşturmak için her sınıfın olasılık dağılımı için varsayım yapılır. Parametrik algoritmalar iki adımdan oluşur: İlki model parametrelerinin tahmin edilmesidir. Bu adımda belli bir sınıfa ait bir pikselin soncul olasılığını belirler. Bu olasılık örneğin Bayes kuralı ile hesaplanabilir. İkinci adımda diskriminant fonksiyonlarının tanımı yapılmaktadır. Burada pikselleri sınıflandırmak için karar

kuralı oluşturulmaktadır. Bu bölümde sıkça kullanılan parametrik sınıflandırma algoritmaları kısaca tanıtılarak kapasiteleri/ sınırlamaları incelenecektir.

3.1.1. Paralelyüz (paralelepiped) sınıflandırma yöntemi

Bu yöntem kontrol (örnekleme) verilerinin spektral bileşenlerinin histogramlarının incelenmesine dayalı çok basit bir kontrollü sınıflandırma yöntemidir. Bir sınıflandırma analistinden en az bilgiyi gerektiren yöntemdir aynı zamanda. Tanımlanan her sınıf için, kullanıcı her bandın minimum ve maksimum piksel değerlerini kullanılmaktadır (Richards ve Jia, 1995). Uygulanan karar kuralı basittir. Her bilinmeyen piksel , özellik değeri ilgili olduğu paralelyüz içine atanır.




Şekil 3.1 : İki boyutta paralelyüz sınıflandırma (Richards, 1995)

Bu yöntemde iki sıradışı durum oluşabilir: Bir piksel değeri hiçbir paralelyüz içine dahil edilemeyebilir ve bir pikselin birden fazla örtüşen paralelyüz içinde olma olasılığı var olabilir (Şekil 3.1). Her iki durumda da karar kuralını uygulamak zorlaşacaktır. Bu tür çelişkilerin giderilmesi için komplike bir kural da uygulanagelmıştır: Her paralelyüzün merkez noktası ile bilinmeyen piksel arasındaki Öklid uzaklığının hesaplanması ve böylelikle en iyi sınıflandırma için " en küçük uzaklık " kuralı uygulaması çözüm olarak ileri sürülmektedir.

Paralelyüz sınıflandırma yöntemi, uygulaması hızlı ve kolay olmasına rağmen; her bir örnekleme seti için özelliklerin yalnızca minimum ve maksimum değerlerini kullanılması nedeniyle, gerçek spektral sınıfların iyi temsil edilememesine yol açmaktadır. Diğer bir sakınca ise, sınıf üyeliklerinin öncül olasılıklarının dikkate alınmamasıdır.

3.1.2. En büyük benzerlik (Max. Likelihood) sınıflandırma yöntemi

En büyük benzerlik sınıflandırma yöntemi uzaktan algılamada görüntü sınıflandırması için en çok kullanılan ve bilinen kontrollü sınıflandırma yöntemidir. Bu yöntem sınıflar için eş- olasılık eğrilerinin tanımlanmasına ve sınıflandırılacak piksellerin üyelik olasılığı en yüksek olan sınıfa atanması ilkesine dayanır (Şekil 3.2). Herhangi bir sınıfa ait piksel setini temsil eden noktalar kümesinin geometrik şekli bir elipsoidle tanımlanırsa, bu elipsoidin yönü ve rölatif boyutları model uzayını tanımlayan özellikler arasındaki kovaryanslara bağlı olacaktır.



Şekil 3.2: İki normal olasılık dağılımı (Mather, 1989)

Şekil 3.2' de iki boyutlu elipsler üzerinde kovaryansları incelemek gerekirse; 1 nolu elips değişkenler (özellik) arasında yüksek pozitif kovaryansı göstermektedir. Yaklaşık daire şekli sıfır kovaryans anlamındadır. Elipsin eksen uzunlukları ise değişkenin varyansları ile orantılıdır. Elipsin konum, şekil ve büyüklüğü iki değişkenin ortalama, varyans ve kovaryans değerlerini yansıtmaktadır. Bu elipslere sınıfların eş-olasılık eğrileri gözüyle bakılabilir. Sınıflandırma yapılırken olasılık eğrisinin şekli önemlidir. (Şekilde P noktası 1. sınıfın merkezine Q noktasından daha yakın olmasına rağmen olasılık eğrisinin şekli nedeniyle 2. sınıfa atanmıştır.) Tüm sınıflar için eş-olasılık eğrileri belirlendiğinde sınıflandırılacak pikseller üyelik olasılığı en yüksek olan sınıfa atanarak sınıflandırma yapılır. Çok boyutlu model uzayında (görüntü) örnekleme veri setine bağlı olarak her sınıfın dağılım şeklinin tahmini yapıldığından, en büyük benzerlik yönteminin sonuç sınıflandırma doğruluğu diğer parametrik yöntemlerden daha iyi olması beklenir.

Bu noktada parametrik yöntemlerden en büyük benzerlik yöntemini, non- parametrik yöntemlerle sınıflandırma doğruluğu ve kapasitesi açısından karşılaştırmak üzere; enbüyük benzerlik yöntemini istatistik açıdan irdelemek yararlı olacaktır:

Bir görüntü içindeki spektral sınıflar w_i , $i = 1,2,...,M$ (M : sınıfların toplam sayısı) ile gösterilirse x konumundaki bir pikselin ait olduğu sınıfın belirlenmesi işi, şartlı olasılıktır.

$$p(w_i | x), i = 1,2,...,M \quad (3.1)$$

x : konum vektörü yani pikselin yansıma değerlerinin sütun vektörüdür. $p(w_i | x)$ olasılığı, x konumundaki bir piksel için doğru sınıfın w_i olma olasılığını verir. Burada sınıflandırma *Bayes Kuralı* 'na göre yapılacaktır:

$$x \in w_i \text{ 'dir. Eğer } p(w_i | x) > p(w_j | x) \text{ tüm } j \neq i \text{ için} \quad (3.2)$$

Ancak burada $p(w_i | x)$ ' ler bilinmediği için örnekleme bölgesi verilerinden tahmin edilir. Örnekleme veri setinden yararlanarak arazi sınıflarının olasılık dağılımlarının bir formu - $p(x | w_i)$ oluşturulur. Buradan istenen $p(w_i | x)$ ' ler elde edilebilecektir (Freund ve Walpole, 1987). Gerekli ilişkilendirme Bayes Kuralı' na göre;

$$p(w_i | x) = p(x | w_i) p(w_i) / p(x) \quad (3.3)$$

yazılabilir. Burada $p(w_i)$: görüntü içinde w_i sınıfının oluşma olasılığını, $p(x)$: x konumundaki pikselin herhangi bir sınıfa ait olma olasılığını göstermektedir. Böylelikle $p(w_i | x)$ olasılığı, örnekleme veri setinden tahmin yoluyla belirlendiği için 'soncul olasılık' olmaktadır. Dolayısıyla sınıflandırma kuralı daha pratik hale gelir:

$$x \in w_i \text{ 'dir. Eğer } p(x | w_i) p(w_i) > p(x | w_j) p(w_j) \text{ tüm } j \neq i \text{ için} \quad (3.4)$$

$$\text{Daha basit olarak ; } x \in w_i \text{ 'dir. Eğer } g_i (x) > g_j (x) \text{ tüm } j \neq i \text{ için} \quad (3.5)$$

yazılabilir. Bu ifade en büyük benzerlik yöntemiyle sınıflandırma işleminde kullanılan karar kuralıdır. $g(x)$ ' ler " diskrimnant fonksiyonu"dur. Bu noktada sınıfların olasılık dağılımlarının çok değişkenli normal model formunda olduğu varsayılmaktadır. Bunun nedeni " normal dağılım " fonksiyonunun özellikleri iyi bilinmesi nedeniyle matematiksel sadelikte bir form elde etmektir. O halde,

$$p(\mathbf{x} | \mathbf{w}_i) = (2\pi)^{-N/2} |\Sigma_i|^{-1/2} \exp \{-1/2(\mathbf{x}-\mathbf{m}_i)^t \Sigma_i^{-1}(\mathbf{x}-\mathbf{m}_i)\} \quad (3.6)$$

Burada N: band sayısı olmak üzere, $\mathbf{m}_i$ ve Σ_i ; $\mathbf{w}_i$ sınıfına ait verilerin ortalama vektörü ile kovaryans matrisidir. En büyük benzerlik yöntemi ile sınıflandırma işlemi için normal dağılım varsayımıyla, diskriminant fonksiyonu formu (eşit öncül olasılık varsayımıyla) aşağıdaki hale gelecektir:

$$g_i(\mathbf{x}) = -\ln |\Sigma_i| - (\mathbf{x}-\mathbf{m}_i)^t \Sigma_i^{-1}(\mathbf{x}-\mathbf{m}_i) \quad (3.7)$$

En büyük benzerlik (max. likelihood) yönteminde diskriminant fonksiyonunun bu formu, sınıflandırmada karar kuralının kapasitesini değerlendirmek açısından önemlidir (bakınız karar yüzeyleri).

Açıklamalardan görüleceği üzere; en büyük benzerlik yönteminin etkinliği, her spektral sınıf için ortalama vektör ile kovaryans matrisin doğru biçimde tahmin edilmesine bağlı olmaktadır. Bu koşul ise, sınıfların her biri için yeterli miktarda örnekleme verisinin (pikseller) bulunabilmesine bağlıdır. Örnekleme bölgesine ait yeterli miktarda veri bulunmadığı zaman (başka bir deyişle; sınıfların olasılık dağılımlarını doğru bir şekilde tahmin edebilecek özellikte veri olmadığı zaman) arzulanan sınıflandırma doğruluklarına ulaşılamaz. Böyle bir durumda kovaryans bilgilerini kullanmayan başka sınıflandırma yöntemlerine başvurmak gerekir.

3.1.3. En küçük uzaklık (Minimum Distance to Means) sınıflandırma yöntemi

Örnekleme bölgelerine ait örnekleme verileri sınırlı olduğu zaman, kovaryans bilgilerini kullanmayan yalnızca spektral sınıfların ortalama vektörlerinin kullanılmasına dayanan sınıflandırma yöntemlerine başvurmak gerekir. Böyle bir durumda kısıtlı örnekten ortalama değerler kovaryanslara nazaran daha doğru tahmin edilebilir. En küçük uzaklık yöntemi (veya sınıf ortalamasına en küçük uzaklıklar) böyle bir yaklaşım uygular. Örnekleme verilerinden sınıf ortalamaları belirlenir, sınıflandırmada bir piksel en yakın ortalamaya sahip sınıfa atanır.

En küçük uzaklık yönteminde diskriminant fonksiyonu, karesel Öklid uzaklıklarının vektörel formu biçiminde yazılabilir:

$$d(\mathbf{x}, \mathbf{m}_i)^2 = (\mathbf{x}-\mathbf{m}_i)^t (\mathbf{x}-\mathbf{m}_i) \quad (3.8)$$

Sınıflandırma için; $x \in w_i$ 'dir. Eğer $d(x, m_i)^2 < d(x, m_j)^2$ tüm $j \neq i$ için, (3.9)

Diskriminant fonksiyonu $g_i(x) = 2 m_i x - m_i$, m_i olacaktır. (3.10)

En küçük uzaklık sınıflandırma yöntemi, en büyük benzerlik yönteminden daha hızlı olduğu için ilgi çekicidir. Ancak kovaryans bilgilerini kullanmadığından en büyük benzerlik yöntemi kadar esnek değildir. Enbüyük benzerlik yöntemiyle sınıflandırmada sınıflar çok değişkenli normal sınıf dağılım modeli yardımıyla modellendirilmektedir. En küçük uzaklık yönteminde kovaryans verilerinin kullanılmaması nedeniyle sınıf modelleri spektral anlamda simetriktir. Bu nedenle bazı sınıflar iyi modellenmeyebilir. Ancak örnekleme verileri sınırlı olduğu zaman en küçük uzaklık yöntemi, en büyük benzerlik yönteminden daha doğru sonuçlar verir.

3.1.4. Mahalanobis sınıflandırma yöntemi

En büyük benzerlik yönteminin diskriminant fonksiyonunu ele alalım ve eşit öncül olasılıklara sahip olduğu varsayalım. Bu fonksiyonun işareti değiştirilirse karesel uzaklık ölçüsü olarak düşünülebilir.

$$d(x, m_i)^2 = \ln |\Sigma_i| + (x - m_i)^t \Sigma_i^{-1} (x - m_i) \quad (3.11)$$

elde edilir ve en küçük uzaklık yönteminde olduğu gibi minimum $d(x, m_i)$ ye göre sınıflandırma yapılır. Böylelikle en büyük benzerlik yöntemi, yöne duyarlı ve sınıflara göre değişebilen bir uzunluk ölçüsüne sahip bir en küçük sınıflandırma yöntemi gibi düşünülebilir. Bu uzaklık ölçüsü;

$$d(x, m_i)^2 = (x - m_i)^t \Sigma^{-1} (x - m_i) \quad (3.12)$$

şeklini alır ve bu yöntem Mahalanobis yöntemi olarak bilinmektedir. Bu yöntemin en büyük benzerlik yöntemine göre üstün olduğu taraf, daha hızlı oluşu ve kovaryans matrisi aracılığıyla yön duyarlılık derecesine sahip olmasıdır.

3.1.5. Karar Yüzeyleri (decision surfaces – decision boundaries)

Sınıflandırma yöntemlerinde multispektral uzayda sınıfları birbirinden ayıran yüzeylerin temel şekillerini belirlemek önemlidir. Spektral sınıflar multispektral uzayda diskriminant fonksiyonlarının en büyük olduğu bölgeleriyle tanımlanır. Bu


bölgeler bitişik spektral sınıfların diskriminant fonksiyonlarının eşit olduğu konumdaki yüzeyler tarafından ayrılabilirler. i .nci ve j .inci spektral sınıflar $g_i(x) - g_j(x) = 0$ yüzeyi ile ayrılırlar. Bu yüzeye “ karar yüzeyi ” denir (Bishop, 1995). Spektral sınıfları ayıran (bölümlendirme) tüm yüzeyler bilinirse görüntü içindeki pikselin sınıf üyeliği ile ilgili kararlar, pikselin konumunun tüm yüzey grubuna göre olan durumuyla verilir.

En büyük benzerlik yönteminde diskriminant fonksiyonunun $(x-m_i)^T \Sigma^{-1}(x-m_i)$ terimi kuadratik formdadır. Yani en büyük benzerlik yöntemiyle sınıflandırma işleminde uygulanan karar yüzeyleri (karar sınırları) kuadrattır; parabol, daire veya elips şeklini alırlar.

En küçük uzaklık yönteminde karar yüzeyleri lineer formdadır. Dolayısıyla en büyük benzerlik yönteminde elde edilen karar yüzeyleri, en küçük uzaklığa göre multispektral uzayın bölümlendirilmesinde daha etkin olmaktadır.

Tam da bu noktada yapay sinir ağlarının bir sınıflandırma yöntemi olarak ele alındığında oluşturduğu karar yüzeylerini irdelemek gerekir. Sinir ağları, her türünde mümkün olmamakla birlikte, yüksek –dereceden karar yüzeyleri oluşturabilme kapasitesine sahiptir (Lippman, 1987).

Konuyu daha yakından irdelemek üzere, iki boyutlu olarak spektral sınıflara ait özellik vektörlerinin şematik gösterimini kullanabiliriz. Şekil 3.3’ de iki sınıfa ait bir sınıflandırma probleminin karar yüzeyleri (sınırları) ele alınacaktır.



Şekil 3.3: Çeşitli sınıflandırma yöntemlerine ait karar yüzeyleri

Şekil 3.3a’ da karar sınırı modelinin basit formu –bir doğru görülmektedir. İki sınıfın görece kötü bir ayrımını vermektedir. Bu tipe örnek olarak en küçük uzaklık sınıflandırma yöntemi verilebilir.

Şekil 3.3b' de daha esnek bir modelin karar sınırlarını göstermektedir. Veri setinin daha iyi bir ayrımını vermektedir. En büyük benzerlik sınıflandırma yöntemi bu tip karar sınırına örnek gösterilebilir.

Şekil 3.3c ise her iki yöntemin karar sınırlarından daha üstün, iki sınıfın mükemmel bir ayrımını verebilecek nitelikte ve çok esnek bir modelin karar sınırlarını göstermektedir. Yapay sinir ağları bu türden karar yüzeyleri (ve diskriminant fonksiyonu) üretebilme yeteneğine sahiptir. Üç tabakalı- ileri itilimli (feedforward) sinir ağları belirtilen nitelikte karar yüzeyleri üretebilme kapasitesine sahiptir. (Bunun sinir ağlarının her türünde mümkün olmadığını da hatırlatmak gerekir. Ayrıca bakınız Şekil 3.13).

Sınıflandırma yöntemlerinin sınıfları birbirinden ayıran yüzeylerin temel şekilleri konusundaki bu karşılaştırma, bize non- parametrik sınıflandırma algoritmalarının parametrik sınıflandırma algoritmalarından daha üstün olduğunu kanıtlamaktadır. Ayrıca çok yaygın olarak kullanılan ve bilinen klasik- parametrik sınıflandırma algoritmalarının (en büyük benzerlik vb.) dahi, doğruluklarının örnekleme veri setine bağlı olması ve veri setinin özelliklerinin önceden bilinmemesi bu yöntemlerin sahip olduğu bazı dezavantajları (sınırlamalar) göstermektedir. Parametrik sınıflandırma yöntemlerinin yetersiz kaldığı bir diğer nokta, örnekleme veri seti büyüklükleri ile ilgilidir. Eğer veri seti miktarları sınıflar arasında belirgin biçimde değişiyorsa, sınıfların soncul olasılıkları doğru biçimde tahmin edilememektedir. Buna ek olarak, klasik sınıflandırma algoritmaları gelişen algılama platformlarının sağladığı büyük hacimli ve çok- kaynaklı verileri kullanma gereksinimi karşılayacak nitelikte değildir. Bütün bu nedenlerden dolayı, uzaktan algılama verilerinin sınıflandırması için daha gelişmiş analiz yöntemlerine ihtiyaç vardır.

3.2. Non- Parametrik Sınıflandırma Algoritmaları

Uzaktan algılama teknolojisindeki son gelişmeler, hiperspektral platformların kullanımı ve yüksek çözünürlüklü algılayıcıların gelişmesi nedeniyle uzaktan algılama verilerinin sınıflandırması için daha gelişmiş analiz yöntemlerine duyulan gereksinim gittikçe artmaktadır.

Klasik sınıflandırma yöntemlerinde (enbüyük benzerlik vb.) örnekleme bölgelerinden sağlanan örnekleme verilerinin normal (Gauss) dağılıma uyduğunun varsayıldığı belirtilerek, bu varsayım altındaki uydu kanal (band) bilgilerinde yardımcı verilerden yararlanılamaması araştırmacıları parametrik olmayan sınıflandırma yöntemlerini

araştırmaya itmiştir. Araştırmalar, örnekleme verilerinin olasılık dağılım diyagramlarının keyfi dağılımlar gösterdiğini ortaya koymuştur (bazen bir hiperelipsoidle bile tanımlanamadığı görülmüş,...vb.).

Bu nedenle örnekleme bölgeleri verilerinin olasılık dağılımlarının, gerçekçi biçimde tanımlanabilmesi için farklı yaklaşımlar geliştirilebilir. Bu amaçla farklı dağılım parametreleri ve istatistik testler (ortalama değer ve standart sapmanın yanında ek parametreler, normalite testi, uyuşum testi,...vb.) kullanılabilir. Ek parametreler kullanılarak tanımlanan dağılımın normal dağılım varsayımından farklı olup olmadığı (signifikant) istatistiksel olarak test edilebilir. (Aslında uzaktan algılama literatüründe bu konuyla ilgili sistematik çalışmalara pek rastlanılmamaktadır. İleride yapılacak araştırmalar için bu nokta iyi bir çıkış noktası olabilir.)

Parametrik sınıflandırma yöntemlerinin yetersiz kaldığı bir diğer nokta, örnekleme veri seti büyüklükleri sınıflar arasında belirgin biçimde değiştiğinde, soncul olasılıkların (posterior probabilités) doğru biçimde tahmin edilememesidir (Lawrence ve diğ., 1998). Böyle bir durumun hem kestirilmesi zordur, hem de belirsizliklere yol açar. Bir sınıflandırma analistinin özen göstermesi gereken noktalardan biri de budur.

Non- parametrik algoritmalar olasılık dağılımları ile ilgili herhangi bir varsayım yapmamaktadır. Bu nedenle standart yöntemlerden daha üstün olduğu vurgulanmıştır. Parametrik olmayan algoritmalar son zamanlarda “ soft computing “ terimi ile birlikte anılmaya başlamıştır. Buna paralel olarak sınıflandırma algoritmaları terminolojisine yeni bir kavram kazandırılmıştır: “ katı ” sınıflandırma (hard classification) ve “ esnek ” sınıflandırma (soft classification) şeklinde çevirebileceğimiz kavramların kullanımı yaygınlaşmaktadır (Bernard ve diğ., 1997; Binaghi ve diğ., 1996). Katı sınıflandırmada her piksele (görüntü elemanı) yalnız ve tek bir sınıf ataması yapılabilirken; esnek sınıflandırmada her piksele çevrenin (doğa) değişen yapısını yansıtacak biçimde birden fazla sınıf ataması yapılması mümkündür. Bu tanım gereği yapay sinir ağları, bulanık mantık, genetik algoritmalar ve hibrid yöntemler esnek sınıflandırma yaklaşımına uyan teknolojilerdir.

Sınıflandırma işleminde, istatistiksel varsayımlardan kaçınmak için yapay sinir ağları birçok otorite tarafından önerilmiştir. Farklı yapay sinir ağı yapıları denenmiş, uygun mimari seçildiğinde sinir ağının klasik yöntemlerden daha iyi sonuçlar verebileceği, yardımcı verilerin (yükseklik, eğim,...) ilişkilendirilmesiyle de (integrasyon) sınıflandırma doğruluğunun artabileceği ileri sürülmüştür. Buna ek olarak yapay sinir

ağının başarıyla uygulanmasını zorlaştıran birçok probleme de (ağ konfigurasyonu, uzun zaman gerektirmesi, uygun parametre seçimi,...vb) değinilmiştir (Solaiman ve Mouchet, 1996; Hepner ve diğ., 1990; Bischof ve diğ., 1992).


3.2.1. Yapay Sinir Ağları (Artificial Neural Networks)

Yapay Sinir Ağları (Artificial Neural Networks) algoritmalarının çeşitli bilimsel alanlardaki uygulamalarında hızlı bir artış görülmektedir. Son araştırmalar sinir ağlarının uzaktan algılama verilerinin sınıflandırma işlemlerinde kullanıldığında etkin bir sınıflandırma yöntemi olabileceğini göstermiştir. Bunun nedeni yapay sinir ağlarının aşağıdaki önemli avantajlarından kaynaklanmaktadır:

- i-) parametrik olmayan yapısı,
- ii-) standart sınıflandırma yöntemlerine ilginç bir alternatif oluşturan “öğrenme” yeteneği,
- iii-) olasılık modeli ile ilgili hiçbir varsayım yapmaması,
- iv-) özellik uzayında yüksek dereceden ve lineer olmayan “karar sınırları” (decision boundary) oluşturma yeteneği,
- v-) Farklı veri türleri ve giriş yapılarına uyum yeteneği (Vieira, 1998).

Son yıllarda araştırmacılar parametrik sınıflandırma yöntemlerinin daha önceki bölümlerde açıklanan dezavantajlarını gidermek için; parametrik - olmayan sınıflandırma yöntemleri geliştirmeye çalışmaktadırlar ve Yapay Sinir Ağları (ANN), uydu görüntülerinin güvenli sınıflandırılması için uygun bir yöntem olarak kabul görmektedir. Tanım olarak sinir ağları; karmaşık transfer problemlerinin çözümü için, birlikte işleyen-birbiriyle bağlantılı, lineer olmayan basit hesaplama birimlerinden (nöron) oluşmaktadır.

Pratikte sinir ağları, özellikle çok miktarda test verisinin olduğu, fakat kesin ve hızlı kuralların kolaylıkla uygulanamayacağı sınıflandırma ve fonksiyon tahmini/ yaklaşım problemlerinde kullanılmaktadır. Vektör uzayları arasındaki hemen hemen her dönüşüm/ bağıntı, pratik uygulamalarda en çok kullanılan tür olan “ ileri- itilimli sinir ağları ” (feedforward neural networks) kullanarak istenilen doğrulukta yapılabilir. Yapay sinir ağı teknolojileri; uzaktan algılama görüntülerinin sınıflandırılması için klasik yöntemlere iyi ve etkin bir alternatif olarak düşünülebilir.



Şekil 3.4: Yapay sinir ağı yapısı (Paola ve Schowengardt, 1995)


Şekil 3.4 'te görüntü sınıflandırmasında kullanılabilecek bir sinir ağı modeli (ileri itilimli) görülmektedir. İleri- itilimli sinir ağı modelinde işlem düğümleri (nöron), tam içbağlantılı tabakalar grubu halinde ve aynı tabaka içinde ara bağlantı olmayacak biçimde kurulur. Şekildeki sinir ağı yapısı giriş, gizli ve çıkış tabakası olmak üzere üç tabakadan oluşmaktadır. Giriş tabakasındaki her nöron giriş özelliklerini (feature) temsil etmektedir (örn. Landsat TM band verisi). Çıkış tabakasındaki her nöron ise spektral sınıfları temsil etmektedir. Giriş tabakasında sınıflara ilişkin veriler sinir ağına girilirken, gizli tabakalar hesaplama amaçları için kullanılır. Gizli tabakalar giriş verilerinin iç- yapısını tanımlamaktadır. Düğümler arasındaki her bağlantı ağırlıklarla (weights) temsil edilir ve ağ içindeki bu ağırlıklar aslında özellik uzayında sınıf sınırlarını belirlemektedir.

Günümüzde en çok kullanılan sinir ağı sınıflandırma yöntemi çok tabakalı algılayıcı sinir ağı (multilayer perceptron network : MLP) olup geniş biçimde analiz edilmiş ve birçok öğrenme algoritmaları geliştirilmiştir. MLP, kontrollu sinir ağı türüne aittir.

Sinir ağı yönteminin temel handikapı , ağın çalıştırılması (train) için çok fazla zaman gerektirmesidir, ancak; uygun bir öğrenme parametresi kullanılarak gereken zaman azaltılabilir. İşlem zamanının fazlalığına rağmen, multispektral sınıflandırma için yapay sinir ağlarının, standart sınıflandırma tekniklerinden (örn. en çok benzerlik yöntemi) daha doğru sonuçlar üretebileceği kabul edilmektedir.

Uzaktan algılamada yapay sinir ağlarının bir diğer olumlu tarafı da; görüntü sınıflandırmasında sinir ağlarının, uzaktan algılama ile diğer yardımcı arazi bilgilerinin integrasyonuna olanak tanımasıdır. En çok benzerlik ve enyakın komşuluk sınıflandırma yöntemi gibi klasik sınıflandırma yöntemleri, yalnızca uydu görüntü band (kanal) bilgilerine uygulanabilmektedir. Oysa sinir ağları; uydu spektral verileri, yardımcı arazi kullanım bilgileri (eğim, görünüm, yükseklik v.b.) ve arazi sınıfları arasındaki lineer ve lineer olmayan bağlantıları sağlamaktadır.


Yapay sinir ağı, insan beyninin korteks kısmının çalışma tarzına benzer şekilde bir yapıda beraber işleyen çok sayıda işleme- elemanından (nöron) oluşan bir bilgisayar işleme sistemi olarak tanımlanabilir (Haykin, 1999). İnsan beyninin rutin olarak gerçekleştirebildiğine benzer biçimde, ileri hesaplama kapasitesine sahip yapay sistemler üretme isteği yapay sinir ağının ilham kaynağı olmuştur. Bir ANN ,her biri az miktarda lokal hafızaya (memory) sahip çok sayıda basit işlemci birimden oluşur (Şekil 3.5). Aşağıdaki şekilde doğal ve yapay nöron görülmektedir.



Şekil 3.5 : Doğal (solda) ve yapay (sağda) nöronun görünümü

Bir ANN, her biri diğerlerine ağırlıklı linklerle bağlı (doğal nöronda *dendrites*) birçok basit birim (beyin hücresi) den oluşur. Bu birimlerin çıkışları (doğal nöronda *axon*) ağ içindeki diğer birimler boyunca geçirilir; ve sonuçta ağın çıkış değeri olur.


Bir sinir ağı birçok işleme elemanından (nöron) oluşur; her bir nöronun giriş verisi ya dış dünyadır veya diğer nöronların çıkış verisidir. Bütün nöronların çıkış sinyalleri giderek etkisini tüm ağ boyunca gösterir ve sonuç tabakaya kadar yayar; sonuçları da gerçek dünyanın sonucu olur. Bir ANN giriş vektörünü aldığı anda çıkış vektörü formunda bir yanıt üretir. Giriş işleme elemanları çıkış birimlerine gizli elemanlarla bağlıdır. Gizli birimler (gizli tabakalar) giriş ve çıkış bilgileri arasındaki non-lineariteyi temsil etmektedir. Şekil 3.6 genel olarak uzaktan algılamada görüntü sınıflandırmasında kullanılabilecek bir sinir ağı yapısını göstermektedir.



Şekil 3.6 : Sınıflandırmada kullanılan bir sinir ağı yapısı örneği

Sinir ağı örneklerden “öğrenir” ve örnekleme verileri (deneme seti) üzerinde “genelleştirme” yeteneğini kullanır. Genelleştirme, sinir ağının örnekleme veri seti içinde yer almayan yeni verileri interpolate/ ekstrapole edebilme yeteneğidir. Bir sinir ağının “gücü”, örnekleme verilerinden ne kadar iyi genelleştirme yapabildiğine bağlıdır (Atkinson ve Tatnall, 1997). Öğrenme algoritması; -istenen (hedef) çıkış vektörü ile gerçekleşen çıkış vektörü arasındaki uzaklık- cinsinden bir ölçü değeri olan hata fonksiyonunu kullanarak; deneme seti üzerindeki ortalama hatayı azaltacak şekilde, ağ içindeki ağırlıkları dengelemektedir. Bu doğru olarak gerçekleştirildiğinde sinir ağı, yeni giriş verileri için istenen sonuçları doğru olarak tahmin edecektir.


Sinir ağı öğrenme problemi, polinom fonksiyonu kullanarak yapılan “eğri uydurma” işlemine çok benzer. Veri noktalarından oluşan bir noktalar kümesine en iyi uyan eğri belirlenirken yapılacak ilk iş, kullanılacak polinom fonksiyonunun optimum derecesini bulmaktır. Sonra, gerekli olan ve tahmin edilen değerler arasındaki farkların karesel toplamını minimum yapacak şekilde fonksiyonun katsayıları tahmin edilir. Böylece polinom fonksiyonu değerleri veri içinde yer alan/ almayan her veri noktası için hesaplanabilir. Eğer polinomun derecesi çok düşük seçilmişse yaklaşım değerleri kötü olacaktır. Diğer taraftan polinomun mertebesi çok yüksek seçilmişse, veri seti içinde olmayan noktalar için iyi olmayan yaklaşım değerleri elde edilebilir. Şekil 3.7’ de gösterim amaçlı şematik bir örnek görülmektedir. Benzer şekilde gereğinden daha basit bir yapıya sahip olan bir sinir ağı, deneme seti içinde yer almayan veriler için bile iyi yaklaşım değerleri üretemez. Gereğinden daha karmaşık (kompleks) bir sinir ağı ise deneme setine aşırı uyar (overfit), yani veri seti içindeki modele iyi uyarken bilinmeyen modeller (pattern) için kötü yaklaşımlar-sonuçlar vermektedir (Bebis ve Georgiopoulos, 1999).



Şekil 3.7: Eğri uydurma- Aşırıuyuma problemi (Bebis, 1999)

Görüldüğü üzere polinomun derecesi arttıkça, eğri veri noktalarına çok yaklaşıyor ancak genelleştirme yeteneğini de yitirmektedir. Buradan sinir ağlarında optimum yapı seçiminin ne kadar önemli olduğu anlaşılabilir.

Sinir ağlarının tabakalar halinde organize edildiği belirtilmişti. Tabakaları oluşturan işleme elemanlarını (nöron) incelemek gerekir. Sinir ağı içindeki her nöron Şekil 3.8' deki gibi modellenilebilir. Burada i : nöronun giriş verisi; w : ağırlık; b : bias; n : toplam giriş ; f : etkinlik fonksiyonu; o : nöronun çıkışı (sonuç).




Şekil 3.8 : Nöron Modeli

$$n = w_{1,1}i_1 + w_{1,2}i_2 + \dots + w_{1,R}i_R + b = w \cdot i + b ; \text{ ve } o = f(w \cdot i + b) \quad (3.13)$$

Şekilde tek girişli nöronun modeli görülmektedir. Toplam giriş değeri bir etkinlik fonksiyonu yardımıyla nöron çıkışını üretir. Bunu biyolojik nöronla ilişkilendirirsek ağırlıklar sinapsın gerilimini temsil ederken toplam giriş hücre yapısını gösterir. Nöron çıktısı ise axon üzerindeki sinyali temsil etmektedir. Genel olarak bir nöron birden fazla giriş değerine sahiptir. Etkinlik fonksiyonu (transfer fonksiyonu) nöron/

ağ sonucunu üretmekte/ şekillendirmekte ve çeşitli formlarda olabilmektedir. En popüler olan üç tanesi Şekil 3.9’ da görülmektedir.




Şekil 3.9 : Genel etkinlik fonksiyonları

Sinir ağı kullanıcıları arasında en çok kullanılan etkinlik fonksiyonu sigmoid fonksiyondur ve giriş fonksiyonunun büyük değerlerini [0,1] aralığına 'sıkıştırılmaktadır'. Ayrıca çok tabakalı sinir ağı (MLP) modelinde en çok kullanılan etkinlik fonksiyonudur.


$$f(n) \approx \frac{1}{1 + e^{-n}} \quad (3.14)$$

Genelde bir nöron yeterli olmayacağından paralel şekilde işleyen nöronlar grubu, yani "tabaka" yapısı gerekli olur (Şekil 3.10).



Şekil 3.10 : Sinir ağı tabaka yapısı

Bu şekilde S adet nörondan oluşan tek- tabakalı sinir ağı (single layer neural network) modeli görülmektedir. Nöron sayısı arttığı için ilgili parametreler vektörel formda (matrislerle) gösterilir. Sinir ağı uygulamalarının çoğunda birden fazlatabakadan oluşan sinir ağları da kullanılmaktadır (Şekil 3.11).



Şekil 3.11: Üç- tabakalı sinir ağı yapısı

Şekilde iki- gizli tabaka ve bir çıkış tabakasından oluşan üç tabakalı sinir ağı yapısı görülmektedir. Farklı tabakalar değişik sayıda nöron içerebilir. Bu sinir ağı modeli görüntü sınıflandırmasında çok kullanılan bir yapıdır. Bu ağın sonuç vektörü;

$$O^3 = f^3 (W^3 f^2 (W^2 f^1 (W^1 i + b^1) + b^2) + b^3) \quad (3.15)$$

şeklinde ardışık olarak çözülen bir algoritmadır. Herhangi bir sinir ağı uygulaması şu genel aşamalardan oluşur :


- verilerin hazırlanması,
- ağ mimarisinin tasarlanması,
- probleme yönelik parametrelerin tahmini (ağın çalıştırılması),
- ağ performansının (doğruluk) değerlendirilmesi.

Uzaktan algılamada yapay sinir ağı uygulamaları ile ilgili olarak en çok kullanılan sinir ağı türü “çok- tabakalı algılayıcı sinir ağı (multilayer perceptron : MLP)” dır (Fine, 1999).

3.2.1.1. Çok- tabakalı algılayıcı sinir ağı (Multilayer Perceptron)

Günümüzde en çok bilinen ve yaygın biçimde kullanılan yapay sinir ağı sınıflandırma yöntemi “çok-tabakalı algılayıcı sinir ağı”dır. Genel amaçlı, esnek ve çoklu tabakalar halinde organize edilmiş birimlerden (nöron) oluşan non-lineer modellerdir. MLP sinir ağı hemen hemen her fonksiyonu tahmin etme/ yaklaştırma özelliğine sahip bir

ağıdır (Şekil 3.12). Birimler genellikle “ileri-tilimli” iç bağlantılara sahiptir. İleri-tilimli bağlantının anlamı; bağlantıların herhangi bir şekilde döngü oluşturmamasıdır. MLP sinir ağının üstünlüğü nöronlarda kullanılan non-linearite yeteneğinden kaynaklanmaktadır.












Şekil 3.12: Çok- tabakalı sinir ağı

Sinir ağının çalıştırılması (öğrenmesi) ağın sonuç değeri ile hedeflenen sonuçlar arasındaki (farkın) hata ölçüsünün minimum yapılması esasına dayanır. Bu değerler çalıştırma (training) aşamasında ‘geriye doğru’ yayılarak ve iteratif biçimde gerçekleştirilir. Algoritma bu nedenle ‘geri-yayılma’ olarak adlandırılır.

Geri yayılma kuralı (backpropagation) hata değerlerini ağ boyunca dağıtmakta ve dolayısıyla gizli nöronlara uyumunu sağlamaktadır. “Gradyen düşme- öğrenme kuralı” (gradient descent) teorisi kullanılarak ağ içindeki her bir ağırlığa düzeltme getirilerek adaptasyonu sağlanmaktadır. Geri yayılma kuralı, aslında ağ içindeki her ağırlığın ilgili hata fonksiyonunun duyarlılığını hesaplamakta ve bu ağırlığı bu duyarlılığa göre güncelleştirmektedir. Dolayısıyla yalnızca lokal bilgiyi kullanmakta ve hesaplanması kolay bir yöntem olmaktadır. Ancak aynı zamanda sakıncalıdır ; yerel (lokal) minimuma yakalanabilir.(Hata yüzeyinin global minimum değeri aranmaktadır..) Geri yayılma kuralının temel handikapı budur. Bu sakıncadan kaçınmak için farklı yöntemler geliştirilmiştir. Tez kapsamında bu olumsuzluğu gidermek ve hızlı çözüm sağlayabilmek amacıyla Levenberg- Marquardt optimizasyon tekniğine dayalı yeni bir yöntem geliştirilecektir.

Şekil 3.13'te bir, iki ve üç tabakaya sahip -algılayıcı sinir ağlarının kapasitesi incelenmektedir. Burada farklı sinir ağı türlerinin oluşturabileceği karar bölgeleri (decision regions) türleri görülmektedir. Tek- tabakalı algılayıcı sinir ağı yarı -düzlem karar sınırları oluşturabilirken; üç tabakalı sinir ağı yapısı, sınıflandırma işleminde


çokyönlü, kompleks karar sınırları oluşturabilme yeteneğine sahiptir. Bir başka deyişle, diskriminant fonksiyonları her şekli alabilmektedir.

Ağ Yapısı	Karar Bölgesi Türü	Karar Sınırı	Sınıfların Durumu	En Genel Bölge Şekli
TEK TABAKA 	YARI DÜZLEM			
İKİ TABAKA 	AÇIK KONVEKS VEYA KAPALI BÖLGELER			
ÜÇ TABAKA 	İSTENİLEN BİÇİMDE			

Şekil 3.13: Tek ve çok- tabakalı sinir ağlarının oluşturduğu karar sınırları (Lippman,1987)

Bu şekil genel olarak, üç- tabakalı sinir ağı modelinin sınıflandırma problemlerinde diğer sinir ağı türlerinden ve parametrik sınıflandırma algoritmalarından daha doğru ve üstün bir yöntem olduğunun kanıtı sayılabilir.

Çok- tabakalı sinir ağları (MLP) genellikle geriyayılma algoritması ile çalıştırılır. Sinir ağının öğrenme işlemi hata fonksiyonunun minimum yapılması esasına dayanmaktadır. En küçük hata değerine sahip noktaya ilişkin ağırlıklar optimum ağırlıklardır. Muhtemel olan en düşük hata değerine sahip teorik çözüm "global minimum" değeridir. Geriyayılma kuralı, çözüm vektör uzayında hata yüzeyinin basamaklı kesitleri boyunca global minimum değerine ulaşmak için gradyen düşme (gradient descent) tekniği uygular (Şekil 3.14). Hata yüzeyinin çoğu kez düzensiz ve



Şekil 3.14 : Global minimum ve gradyen düşme kuralı

karmaşık bir yapıya sahip (birçok 'çukur ve tepe' içerir) olması nedeniyle, sinir ağı en uygun çözüm olmayan "yerel minimum" değerine yakınsayabilir.

Ağ ağırlıkları istenen ve gerçekleşen ağ sonuçları arasındaki fark ölçüsüne dayanan bir hata değerini minimum yapacak şekilde dengelenmektedir. Hata fonksiyonu;

$$E^p = \frac{1}{2} \sum_j (d_j^p - o_j^p)^2 \quad (3.17)$$

olarak tanımlanabilir. (d_j : istenen sonuç, o_j : gerçekleşen ağ sonucu ve p : pattern) Ağırlıkları dengelemek (ağ düzeltmesi) için hata fonksiyonunun gradyeni kullanılır.

$$\Delta^p w_{ji} = -\eta \cdot \left(\frac{\partial E^p}{\partial w_{ji}} \right) \quad (3.18)$$

Burada ağırlık düzeltmesi için kullanılan η sabitine "öğrenme oranı" denilmekte olup; ağırlık değişimi için hesaplanacak hata duyarlık değerini belirlemektedir. "En iyi" öğrenme oranı değeri hata yüzeyinin özelliklerine bağlıdır. Ağırlıkların dengelenmesi;

$$w_{ij}(t+1) \cong w_{ij}(t) + \eta \cdot \delta_j \cdot i_i \quad (3.19)$$

göre yapılır. Burada $w_{ij}(t)$: t zamanında i giriş (veya gizli) düğümü ile j düğümü arasındaki ağırlık, i_i : ya i düğümünün sonuç değeri veya bir giriş, δ_j : j düğümünün hata terimidir. Bir çıkış düğümü için hata terimi ;

$$\delta_j \cong o_j \cdot (1 - o_j) \cdot (d_j - o_j) \quad (3.20)$$

burada d_j : j düğümünün istenen sonuç değeri, o_j : gerçekleşen sonuç değeridir. j düğümü bir gizli düğüm ise;

$$\delta_j \cong o_j \cdot (1 - o_j) \cdot \sum_k \delta_k \cdot w_{jk} \quad (3.21)$$

k : j düğümü üstündeki tabakalardaki düğümdür. Bazen bir "momentum" teriminin (α) eklenmesi yakınsamayı hızlandırmakta ve ağırlık değişimleri 'yumuşatılmaktadır'.

$$w_{ij}(t+1) \cong w_{ij}(t) + \eta \cdot (d_j - o_j) \cdot i_i + \alpha \cdot (w_{ij}(t) - w_{ij}(t-1)) \quad (3.22)$$

Ne varki yaygın olarak kullanılan bu algoritma uzun zaman gerektirmektedir. Bu nedenle algoritmanın çözümünü hızlandırmak için çeşitli araştırmalar yapılmıştır. Ayrıca ağırlık güncellemelerini ardışık biçimde ve lokal olarak hesapladığı için yerel minimuma yakalanma riski vardır.

3.2.1.2. Yapay sinir ağlarında doğruluk güven tahmini

Çok- tabakalı ileri- itilimli sinir ağları pratikte sınıflandırma ve regresyon problemlerinin çözümünde yaygın biçimde kullanılmaktadır. Uygulamalarda güvenilir ve pratik bir “güvenlik tahmin” ölçüsü çok gereklidir. Yapay sinir ağlarında (kontrollü öğrenmede) bir sınıflandırma yöntemi örnekleme setine (deneme seti) bağlı bir öğrenme algoritması kullanılarak oluşturulur. Kurulan yöntemin performansı genellikle “genelleştirme doğruluğu veya gerçek doğruluk” değerleriyle ölçülür. (Buradaki doğruluk, yöntemin örnekleme seti içinde yer almayan verileri doğru biçimde sınıflandırma olasılığıdır.) Ancak gerçek doğruluk değeri, pratikte sınıflandırma yöntemini test edebilmek için istenilen büyüklükte ve bağımsız bir veri seti her zaman var olamayacağından dolayı doğrudan elde edilemez. Bunun yerine elde mevcut olan küçük (sınırlı) veri grubuna dayalı olarak gerçek doğruluk tahmini yapılır (Kohavi, 1995).

Bir sinir ağı çalıştırıldığında kullanıcı sınıflandırmak için güven değerini (confidence value) bilmek isteyecektir. Sınıflandırmadaki diskriminant fonksiyonu için toplam hata oranı ile ilgili konular bilinmektedir, ancak burada belli bir sınıflandırmanın doğru olma olasılığı ile ilgilenilmektedir. Sınıflandırmanın güvenliği çeşitli yöntemlerle ve ağı farklı tabakaları için tahmin edilebilir. Güven tahmin değeri bir objenin tek bir sınıflandırması için oluşturulmak istenirse aşağıdaki yol izlenebilir:

Bir sinir ağının belirlediği diskriminant fonksiyonu S olsun. $S(x) : x \rightarrow w$ yazılabilir. Burada S diskriminant fonksiyonu, x örnek setine w sınıf etiketini atmaktadır. Her x örnek seti için sınıflandırma S değerinin doğru veya yanlış olmasına göre değişecektir ve buna göre doğruluk fonksiyonu C tanımlanabilir :

$$C(x, w) = \begin{cases} 1 & S(x) \cong w \\ 0 & S(x) \neq w \end{cases} \quad (3.23)$$

bağıntıda w , örnek setin doğru sınıf etiketi (atama) anlamındadır. Sınıflandırılmamış bir örnek objesi sınıflandırılacağı zaman “güven” terimi sınıflandırmanın doğru olma

olasılığı anlamına gelmektedir. Belirli bir sinir ağında bilinmeyen x objesi için güven tanımı şu şekilde yapılabilir:

$$q(x) = P(C(x, w) = 1|x) \quad (3.24)$$

Böylelikle sınıflandırma güvenliği, tahmin edilen sınıfın soncul olasılığıdır. Bu nedenle güven terimini açık formda yazabiliriz:

$$q(x) = \frac{P_w f_w(x)}{f(x)} \quad (3.25)$$

Burada $f_w(x)$: w sınıfı için sınıf yoğunluk fonksiyonu, P_w :öncül sınıf olasılığı ve $f(x)$: x 'in birleşik dağılımı'nı göstermektedir. Bilinmeyen dağılımlar için $q(x)$ tahmin edilecektir (Hoekstra ve diğ., 1996). Tanımlanan güven değerinin kestirilmesi için farklı yöntemler vardır.

Oluşturulacak sinir ağı güvenlik tahmin yöntemi çeşitli nedenlerden dolayı "belirsizliklere" sahip olacaktır. Bu belirsizliklere deneme seti (örnekleme) içindeki hatalar ve modelin sınırlı oluşundan kaynaklanan hatalar neden olur. Deneme seti içinde doğal olarak var olan hatalar 'veri bozunum varyansı' nı (σ_v^2) oluşturur. Sinir ağları belli bir optimizasyon algoritması ile çalıştırıldığından 'model belirsizliği' ne sahip olur ve model belirsizlik varyansı (σ_m^2) ile ifade edilir. Yöntemlerde bu iki belirsizlik kaynağının bağımsız olduğu varsayılarak toplam tahmin varyansı tanımlanabilir. ($\sigma_{Top}^2 = \sigma_v^2 + \sigma_m^2$) Güven tahmin yöntemi her iki kaynağı da dikkate almak durumundadır (Edwards ve diğ., 2000).

Güven değerinin tahmin edilmesinde geliştirilen yöntemler incelendiğinde farklı yaklaşımlara göre kurgulandıkları öne sürülebilir. Bunlar, bir objenin tek bir sınıflandırmasına dayanan yöntemler ve örnekleme veri setine dayalı olarak sonuçların dağılımını modellendiren yöntemler olarak gruplandırılabilir. Karşılaştırma kriterleri de buna göre oluşturulursa uygulama sonuçlarının değerlendirilmesi ve yorumlanması daha pratik olabilir.

Güven değerinin bir objenin tek bir sınıflandırması için tahmin edilmesine dayanan yöntemleri kısaca tanıtmak gerekirse, bunlar en yakın komşuluk, Parzen yöntemi ve Lojistik yöntemidir. En yakın komşuluk (nearest neighbour) yöntemi bilinen bir uzayda (giriş, gizli, sonuç tabakaları) tanımlanan uzaklıkta bir test örneğine en yakın olan öğrenme örneklerini belirler. Bu örnek için güven tahmini;

$$q_{knn} = \frac{N_w}{k} \quad (3.26)$$

olarak tahmin edilir. Burada N_w : k adet en yakın komşuluk arasında doğru sınıfların örnek sayısıdır. Parzen yöntemi, sınıf dağılımları ve diskriminant analiz yaklaşımlarını kullanması nedeniyle yüksek boyutlu çözüm uzayında çoğu zaman başarılı sonuç vermemektedir. Lojistik yöntem basitliği ve hızlı uygulanabilme özelliği nedeniyle tercih edilmektedir. Şartlı sınıf yoğunluklarının bir sigmoid fonksiyonla yaklaşık olarak belirlenebileceği varsayılır. İki sınıftan oluşan bir sınıflandırma probleminde (A ve B sınıfları);

$$P(B | x) = \frac{1}{1 + \exp(\beta x + \beta_0)} \quad (3.27)$$

bağıntı $P_A = P_B$ varsayımı ile yazılmıştır. Bu yöntem daha fazla sınıflara da genişletilebilir. Araştırmalar bu üç yöntemden en yakın komşuluk yönteminin diğerlerden daha iyi sonuç verdiğini göstermiştir (Duin, 1993; Tholen, 1995).

Güven değerinin tahmin edilmesinde örnekleme veri setine dayalı olarak geliştirilen yöntemlerin kullanımı görece daha yaygındır. Sınıflandırma yöntemlerinin performansını ölçmek için kullanılan bu yaklaşımda orijinal veri setine bağlı olarak güven kestirimi yapılmaktadır. Veri kaynaklarının sınırlı oluşu ve veri toplamının pahalı oluşu ve dolayısıyla, orijinal veri setinin büyüklüğünün (boyut) genellikle küçük olması nedeniyle genelde izlenen yol; küçük veri grubuna göre gerçek doğruluğun tahmininin yapılmasıdır. Tahmin edilen doğruluk gerçek doğruluktan yüksek varyans (veya bias) yüzünden sapmaktadır. Yapılacak kestirimin kalitesi büyük oranda uygulanan yöntemle bağlı olacaktır. Bunlar arasında en çok kullanılanlar; standart test/ deneme yöntemi, 'bootstrap' ve çapraz doğrulama (cross validation) yöntemidir.

Standart test etme yönteminde orijinal veri grubu (S) iki ayrı altgruba bölünür : Bu altgruplardan bir tanesi deneme seti (S_1), diğeri test seti (S_2) olarak doğruluk değerlendirmesinde kullanılır. Örnekleme seti sınıflandırma algoritmasını çalıştırmak için kullanılırken, test seti sınıflandırma yönteminin doğruluk tahmini için kullanılır. Bu işlem bir çok kez (N) tekrarlanır, her defasında veri setinin rastgele bir bölümü seçilmektedir. İterasyonların ortalaması alınarak da gerçek doğruluk değerinin tahmin değeri elde edilmiş olur.

Bootstrap yöntemi istatistikte yaygın biçimde kullanılmakta olan bir yöntem olup, bu yöntemde orijinal veri seti (S) içinde, yeniden-örnekleme tekniği kullanılarak N adet altgrup ($S_1, S_2, \dots, S_N$) yaratılmaktadır. M modele (pattern) sahip S setinden S_i 'leri üretmek için, S setinden rastgele bir e patterni seçilir ve S_i içine eklenir. Bu seçim işlemi M kez tekrarlanır. S_i içinde bazı patternler birden fazla yer alabilir veya hiç yer almayabilir. Burada S_i 'ler örnekleme seti olarak kullanılacaktır. Bu şekilde oluşturulan sınıflandırma işleminde sonuç doğruluk ortalama alınarak hesaplanır (Dietterich, 1998).

Diğer yöntem, otomatik uygun ağ mimarisi seçimi için de kullanılan çapraz doğrulama yöntemidir. Çapraz doğrulama yönteminde, bir veri seti (S) öncelikle eşit büyüklükte n adet rastgele ve ayrık altgruplara ($S_1, S_2, \dots, S_N$) ayrılır. Her n altgrup sırayla test seti olarak ve kalan $(n-1)$ altgrup da deneme seti (örnekleme seti) olarak ele alınır. Böylece sınıflandırma yöntemi için deneme seti kullanılırken doğruluk için de test seti kullanılır. Bu işlem her defasında farklı bir altgrup test seti olarak ele alınıp n kez tekrarlanır. Bu yöntemde de gerçek doğruluk n alt grubun ortalaması alınarak belirlenir. Çapraz doğrulamanın ayırtedici özelliği tüm test setinin bağımsız olması ve böylelikle orijinal deneme seti içindeki her "durumun" yalnızca bir defa test edilmesidir. Buna karşın yukarıda anlatılan iki yöntemde bazı durumlar birçok kez test edilirken, bazen hiç test edilmemektedir. Çapraz doğrulama yönteminin bazı varyasyonlarına da rastlanılmaktadır. Bunlardan biri "katmanlı yapıda çapraz doğrulama"dır.

Sinir ağlarında doğruluk –güven tahmininin yanında genel olarak ağdan kaynaklanan (verilerden, modelden kaynaklanan belirsizlikler) belirsizliklerin tahmin edilmesine dayanan yaklaşımlar da kullanılmaktadır. Bu yaklaşımda aslında genel anlamıyla sinir ağı belirsizliği modellenmeye çalışılmaktadır. Bu yöntemlerde belirsizliğin oluşturduğu toplam tahmin varyansı elde edilmeye çalışılır. Söz konusu yöntemlere örnek olarak, yaklaşık Bayes ve enbüyük komşuluk yöntemleri verilebilir (Tibshirani, 1996; Heskes, 1997).

3.2.1.3. Sinir ağlarında doğruluk güven tahmini için yeni bir yöntem

Sinir ağları doğruluklarının kestirilmesinde istatistik teorisine dayalı bir yaklaşım kullanılacaktır. Doğruluk kestiriminde güven aralıklarının (confidence intervals) kurulmasında "binom denemeler kuramından" yararlanan yeni bir algoritma geliştirilecektir. Bu teknik yardımıyla, çalıştırılan bir sinir ağının önceden belirlenen bir hata sınırı içinde ve güven düzeyinde, ağın sonuç değerlerini kullanarak

istatistiksel anlamda ağın kabul edilebilirliği üzerinde bir test ölçütü oluşturulmaktadır. Bu amaçla önce örnekleme veri grubu üzerinde rastgele (random) ölçü grupları seçilmekte, bu grubun ağ sonuçları önceden belirlenmiş hata sınırı değeriyle karşılaştırılarak elde edilecek farklılıkların istatistiksel güven aralıkları hesaplanmakta ve sonuçta bu değerlerin istenen güven düzeyinde olup olmadığına bakılarak sinir ağı modelinin kabul edilebilirliği test edilmektedir.

Bu amaçla öncelikle binom denemeler teorisini kısaca açıklamak gerekir. Olasılık teorisinde bazı deneyler, her biri iki cins sonuçlu, bağımsız denemelerin tekrarlanmasından meydana gelir. Bir deney bağımsız n binom denemesinden meydana gelsin; her denemede başarı olasılığı p ve başarısızlık olasılığı q olsun. Böyle bir deneyin tam tamına x tane başarı ve $n - x$ tane başarısızlıkla sonuçlanma olasılığı ;

$$P(X = x | n, p) = \binom{n}{x} p^x q^{(n-x)} \quad x=0,1,2,\dots,n \quad (3.28)$$

Bir binom deneyinin her denemesinde başarı olasılığı p olsun, n denemedeki başarı sayısının ortalama değeri (umulan değeri) ile varyansı;

$$\mu = E(X) = np \quad ; \quad \sigma^2 = npq \quad (3.29)$$

n büyük değerler alırsa binom dağılımı, standart normal dağılıma çok yaklaşacak şekilde ayarlanabilir (Alder, 1972). Bir binom deneyinin bir tek denemesi için başarı olasılığı olan p' ye biçilen sayısal bir değer nasıl elde edilebilir sorusuna yanıt aranmaktadır. X başarı sayısını göstermek üzere p' ye biçilen değer;

$$\bar{p} = \frac{X}{n} \quad (3.30)$$

olarak tanımlanır. X bir rastlantısal değişken olduğu için $\bar{p}$ 'de rastlantısal değişkendir. $\bar{p}$ ye p' nin etkilenmemiş değer biçicisi (tahmin değeri) denir. Ortalaması $E(\bar{p}) = p$, varyansı ise $\sigma_p^2 = pq / n$ olur. Ayrıca p 'nin bulunabileceği güvenlik aralığını (confidence intervals) belirlemek gerekir. Herhangi bir pozitif d sayısı için $n \rightarrow \infty$ iken $|\bar{p} - p| \leq d$ eşitsizliğinin sağlanması olasılığı 1'e gider. Bunun anlamı, n' yi yeter derecede büyük tutarak $\bar{p}$ değerinin p' den belirlenen bir d uzaklığı içinde bulunmasını istenilen kadar güvenilir duruma getirilebilir. P binomial parametresi için güvenlik aralığı;

$$\bar{p} - h\sqrt{\bar{p}\bar{q}/n} \leq p \leq \bar{p} + h\sqrt{\bar{p}\bar{q}/n} \quad ; (\bar{q} = 1 - \bar{p}) \quad (3.31)$$

bağıntıda geçen h standart sapmadır ve güvenlik seviyesi normal dağılım tablosundan elde edilebilir. Böylece $\bar{p} \pm h\sqrt{\bar{p}\bar{q}/n}$ aralığına “güvenlik aralığı” adı verilir. Eşitsizliğin sol ve sağ tarafına da “alt ve üst güvenlik sınırları” denilmektedir.

Açıklanan bu teoremler yardımıyla çok- tabakalı bir sinir ağını, verilen bir güven düzeyinde ve belirlenen bir doğruluk derecesinde çalıştırabilecek şekilde yeni bir algoritma tasarlanacaktır. Bu algoritma şu aşamalardan oluşacaktır:

- ◆ Örnekleme veri (giriş) setinin oluşturulması,
- ◆ Çok- tabakalı sinir ağı (ileri- itilimli) yapısının seçimi ve çalıştırılması,
- ◆ Sinir ağı doğruluk değeri için güven düzeyinin seçimi (%95 vb.),
- ◆ Sinir ağı hatası için bir “hata sınırı”nın (ϵ) seçimi,
- ◆ İstenen hata sınırını aşan ağ olasılığı-tolerans değerinin belirlenmesi (p_{tol}),
- ◆ Giriş veri grubundan rastgele seçilen m adet noktada ($m > 30$ olmalı) sinir ağı hatasının hesaplanması ($\delta_1, \delta_2, \dots, \delta_m$),
- ◆ Hata sınırını geçen ağ noktaları için, m denemede n başarı sayısının belirlenmesi ve ($\bar{p}$ ve $\bar{q}$) hesabı, olmak üzere ;
- ◆ Alt ve üst güvenlik sınırlarının hesabı, $p_{üst} = \bar{p} + h\sqrt{\bar{p}\bar{q}/n}$ üst güvenlik sınırı olmak üzere, $p_{üst} \leq p_{tol}$ ise tasarlanan ağ (doğruluğu) kabul edilir. Değilse reddedilir.

Böylelikle algoritma yardımıyla çalıştırılan bir sinir ağına önceden belirlenen bir hata sınırı içinde ve belirli bir güven düzeyinde, ağ sonuçlarını kullanarak istatistiksel anlamda ağı kabul edilebilirliği üzerinde bir test ölçütü oluşturulmaktadır. Algoritmayı uygulamak için kullanımı kolay ve pratik bir yazılım geliştirilmiştir (Şekil 3.15). Yazılımda ayrıca, örnekleme veri seti çok büyük olduğu zaman kullanılmak üzere “Poisson dağılımı” hesabına da yer verilmiştir. Örnekleme veri seti çok büyük olduğu zaman Poisson dağılımı binom dağılımı için (dağılımın yaklaşık olarak

hesaplanmasında) normal dağılımdan daha doğru bir alternatiftir. Bu nedenle örnekleme veri seti çok büyük olarak seçildiğinde kullanılmak üzere, yazılımda Poisson dağılımı kullanılmalıdır.

Şekil 3.15 : Sinir ağlarında doğruluk güven tahmini yazılımı

Bu yazılımla, seçilen bir sinir ağı yapısı çalıştırıldıktan sonra örnekleme veri setinden rastgele seçilen ağ noktaları sayısı, güven düzeyi ve ilgili noktaların hesaplanan hata değerleri girildiğinde, hesaplanan ağ sonuç doğruluklarının güvenlik aralığı değerleri hesaplanabilmektedir.

Örnekleme veri seti büyüklüğüne bağlı olarak Poisson dağılımı kullanılabileceği belirtilmişti. Bu dağılımın binom dağılımından bir diğer farkı; binom dağılımında ilgili tüm denemeler dikkate alınırken Poisson dağılımında yalnızca özel sonuçlara ilişkin durumlar inceleme konusudur. Poisson olasılık dağılımı;

$$P(X = x | \lambda) = \frac{e^{-\lambda} \lambda^x}{x!}, \quad x=0,1,2,\dots,n \quad (3.32)$$

olarak tanımlanır. Burada λ : aralık içinde olayların (deneme) ortalamasıdır. Ortalama değer ve varyansı ise ; sırasıyla $\mu = \lambda$ ve $\sigma^2 = \lambda$ olarak tanımlanmıştır. Açıklanan algoritma ve yazılım yardımıyla, yapay sinir ağı sınıflandırma doğruluğunun güvenlik tahmin değeri için yeni bir yöntem geliştirilmiş olmaktadır.

3.2.1.4. Sinir ağlarında hızlı çözüm sağlayan yeni bir algoritma tasarımı

Geri yayılma kuralı birçok nedenden dolayı sinir ağı uygulamalarında tercih edilen bir algoritmadır. Uygulama ve yorumlanmasının kolaylığı ve büyük veri grupları üstünde çalışabilme yeteneği, bu yöntemin üstün argümanlarıdır. Ancak, çalıştırma işleminin uzun zaman alması, hata fonksiyonunun lokal bilgisine dayalı oluşu nedeniyle yerel minimuma yakalanması yöntemin dezavantajlarıdır. Veri grubu büyüklüğü sınırlı olduğu durumlarda da geri yayılma en iyi seçenek değildir. Bu nedenle non- lineer optimizasyonu gerçekleştirmek için geri yayılmadan daha üstün bir yöntem kullanılmalıdır (Masters, 1995).

Non –lineer optimizasyon problemlerinde tek ve en iyi bir yöntem yoktur. Çözülecek problemin özelliklerine en iyi uyan bir yöntem seçilmelidir. Levenberg- Marquardt yöntemi genel olarak diğer yöntemlerden daha iyi şekilde optima değerini bulmaktadır. Levenberg- Marquardt yöntemi sadece sinir ağı uygulamalarında değil, genel non- lineer optimizasyon problemlerinde başarıyla uygulanabilen bir yöntemdir.

Bu çalışmada non- lineer optimizasyonu gerçekleştirmek için geri yayılmadan daha üstün bir yöntem olan Levenberg- Marquardt yöntemine dayanan bir algoritma (yeni bir varyasyon) geliştirilecektir. Hızlı oluşu, global minimuma yakınsama garantisi, sayısal kesinliğe sahip oluşu ve az sayıda kullanıcı- tanımlı giriş parametresi gerektirmesi bu yöntemin temel üstünlüklerindendir.

Genel olarak Levenberg- Marquardt yöntemi, non- lineer fonksiyonların kareleri toplamını minimum yapacak biçimde tasarlanmış, Gauss- Newton optimizasyon yönteminin varyasyonu şeklinde bir algoritmadır (Magnus ve diğ., 1997). Sinir ağı uygulamalarında Levenberg- Marquardt yöntemi, istenen sonuç değerleri ile gerçekleşen ağ sonuçları arasındaki fark cinsinden hesaplanan düzeltmelerin kareleri toplamının minimum yapılması için bilinmeyen ağ parametrelerinin dengelenmesi esasına dayanır. Bu tanımla,

$$\{ e_j^T e_j \} = \min_w \quad (3.33)$$

Hata fonksiyonu cinsinden yazılırsa,

$$E^p = \frac{1}{2} \sum e_j^p = \frac{1}{2} \sum e_j^{p^T} e_j^p = \min. \quad (3.34)$$

Optimizasyon yöntemi her iterasyonda bilinmeyenleri, $\omega^{(i+1)} = \omega^i + \delta^i$ bağıntısına göre dengelemektedir. δ^i düzeltmesi aşağıdaki denklem sisteminden elde edilir :

$$(J^i J^{iT} + \lambda^i I) \delta^i = -J^{iT} e^i \quad (3.35)$$

Denklem sisteminde λ : Marquardt parametresi olarak bilinir ve otomatik olarak dengelenmektedir. J : Bilinmeyenlere göre düzeltmelerin birinci türevlerini içeren Jacobien matristir. $H = J^T J$ sinir ağı literatüründe çok kullanılan Hessian matristir.

$$J(x) = \begin{bmatrix} \frac{\partial e_1(x)}{\partial x_1} & \frac{\partial e_1(x)}{\partial x_2} & \dots & \frac{\partial e_1(x)}{\partial x_n} \\ \frac{\partial e_2(x)}{\partial x_1} & \frac{\partial e_2(x)}{\partial x_2} & \dots & \frac{\partial e_2(x)}{\partial x_n} \\ \frac{\partial e_N(x)}{\partial x_1} & \frac{\partial e_N(x)}{\partial x_2} & \dots & \frac{\partial e_N(x)}{\partial x_n} \end{bmatrix} \quad (3.36)$$

Geri yayılma algoritması gibi Levenberg- Marquardt algoritması da bir tür arama tekniğidir. θ : parametre vektörü olmak üzere, yapılacak yeni iterasyon;

$$\theta^{k+1} = \theta^k + \mu^k \delta^k \quad (3.37)$$

θ^{k+1} :yeni iterasyon, θ^k :şimdiki iterasyon, μ^k :basamak sayısı, δ^k :yönü göstermektedir. Arama yönünün belirlenmesinde de farklı algoritmalar uygulanmaktadır. Tez kapsamında, yakınsamayı hızlandırabilmek için Levenberg-Marquardt yönteminde Marquardt parametresinin elde edilmesinde farklı bir yol izlenecektir. Böylece yöntemin yeni bir versiyonuna ulaşılmış olacaktır.


Algoritma şu aşamalardan oluşacaktır:

- 1- Başlangıç değerlerin girilmesi,
- 2- $(J J^T (\theta^k) + \lambda^k) \delta^k = -J^T (\theta^k) e^k$ denklem sistemini çözerek arama yönünün belirlenmesi,
- 3- Sinir ağını çalıştırın ve $E (\theta^k + \delta^k)$ ile hatanın tahmin değeri $(E^k - E (\theta^k))$ nin belirlenmesi,

- 4- $E^k - E(\theta^k + \delta^k) > 0.70(E^k - E(\theta^k))$ ise $\lambda^{k+1} = 0.5\lambda^k$ seçilir,
- 5- $E^k - E(\theta^k + \delta^k) < 0.30(E^k - E(\theta^k))$ ise $\lambda^{k+1} = 2\lambda^k$ seçilir,
- 6- $E_N(\theta^k + \delta^k) < E_N(\theta^k)$ ise $\theta^{k+1} = \theta^k + \delta^k$ yeni bir iterasyon olarak ele alınır, değilse 2. adıma git ve işlemler tekrarlanır.

Bu yöntemin klasik geriyayılma (ve basamaklı düşme tekniği) algoritmasından üstün olmasını; hızlı oluşunun yanısıra, hata yüzeyinin eğriliğine de duyarlı olmasından kaynaklandığını söyleyebiliriz. Hata yüzeyinin eğriliği genellikle her doğrultuda (yön) aynı değildir. Geriyayılma algoritması belirtilen doğrultu duyarlılığına sahip değildir, önerilen algorithmada ise bir tür "eğrilik yönü tahmini" yapılarak optima değerinin bulunmasında daha hassas bir çözüme ulaşılmaktadır. Burada bir bakıma gradyen düşme tekniği, Hessian matrisin kullanımıyla daha duyarlı ve etkin hale getirilmektedir.

Sözkonusu algoritmayı çok- tabakalı sinir ağı uygulamalarında kullanmak üzere bir yazılım geliştirilmiştir (HYSA : Hızlı Yapay Sinir Ağı), (Şekil 3.16).



Şekil 3.16 : Hızlı Yapay Sinir Ağı Yazılımı

Yazılım yalnızca çok- tabakalı ileri- itilimli (feedforward) sinir ağı mimarisi için tasarlanmıştır. Sınıflandırma problemi ile ilgili giriş değerleri (piksel değerleri) ve test seti hedef verileri bir dosyaya kaydedildiğinde, yazılım açıklanan algoritmaya göre çalıştırma işlemine başlamaktadır. Kullanıcı ağ yapısını ve parametreleri (düğüm sayısı, tabakalar, transfer fonksiyonu,..vb.) tanımlayabilmekte, ayrıca çalıştırma esnasında sonuç değerleri ile ağırlıkların tablolar ve grafik sunumları gerçekleştirilebilmektedir. Algoritmada belirtildiği şekilde sinir ağı sonuç değerleri ile hedeflenen değerler arasındaki farklar *düzeltilme* olarak ele alınır. Düzeltmelerin kareleri ağ ağırlıklarının güncellenmesiyle minimum yapılmaya çalışılır. Marquardt parametresi (Marq.) ve iterasyon sayısı (İtrs.) çalıştırma esnasında da görüntülenecektir. Yazılımın penceresinde, çalıştırma esnasında ve sonra 'düzeltmelerin kareleri toplamı' (Dkt.), ile 'karesel ortalama hata' (koh.) değerleri görüntülenecektir. Karesel ortalama hata, n düzeltmelerin sayısı olmak üzere;

$$koh. = \sqrt{\frac{Dkt.}{n}} \quad (3.38)$$

bağıntısına göre hesaplanacaktır. (Dkt.: düzeltmelerin kareleri toplamı) Yazılım en fazla dört-tabakalı olacak şekilde ve her tabakaya en fazla 20 düğüm olacak şekilde tasarlanmıştır. Geri yayılma algoritması ve gradyen düşme tekniği ile çalıştırılan bir sinir ağına kıyasla, bu yazılım oldukça hızlı ve kullanımı kolay bir seçenek oluşturmaktadır.

3.3. Yapay Sinir Ağları Kavramı İçinde İrdelenmesi Gereken Bazı Sınıflandırma Algoritmaları

Standart sınıflandırma algoritmalarının kapasitesini arttırmak amacıyla bu yöntemlerle birlikte kullanım alanı bulan ve yapay sinir ağları ile yakından ilişkili-benzer bazı sınıflandırma tekniklerinin performanslarını incelemek ve karşılaştırma yapmak yararlı olacaktır. Söz konusu algoritmalar için eklektik bir yaklaşım kullanılacaktır. Literatürde yapay sinir ağlarının görüntü sınıflandırması için bu anlamıyla sistematik biçimde irdelenmemiş (ya da kısmen incelenmiş) olması şaşırtıcıdır.

ECHO (Extraction and Classification of Homogeneous Objects) konumsal- spektral sınıflandırma yöntemidir; spektral varyasyonlar kadar konumsal etkenlerin karar verme aşamasında dikkate alındığı bir yöntemdir. İki aşamadan oluşmaktadır; önce

görüntü istatistik olarak homojen bölgelere ayrılmakta, sonra enbüyük benzerlik obje sınıflandırması planına göre veriler sınıflandırılmaktadır. Klasik enbüyük benzerlik yöntemi gibi uygulanmakla beraber, sınıflandırmada kullanılacak konumsal ilişkinin derecesi ve özelliğini kullanıcının tanımlayabilmesi için ek parametrelerin seçimi gereklidir (Jensen, 1996).

Bölümlendirme işleminden sonra istatistiksel homojenlik testi uygulanmakta ve homojen bölgeler en büyük benzerlik sınıflandırma yöntemine göre sınıflandırılmaktadır. Böylelikle homojen bölgeler içinde yer alan izole hücrelerin (elemanların) uygun biçimde sınıflandırılması sağlanmaktadır. Homojenlik testi seçilen bölgeler için tamamlandıktan sonra bu bölgeler enbüyük benzerlik sınıflandırma planına uygun olarak sınıflandırılmaktadır. Kullanıcı tarafından uygun parametre değerleri seçildiğinde, ECHO genellikle bir piksel bazlı sınıflandırma yöntemine göre daha yüksek doğruluk sağlamak ve daha az zaman gerektirmektedir.

Polinom (diskrimnant) sınıflandırma algoritması, normalleştirilmiş bir görüntü içinde piksellerin polinom terimlerini özellik olarak kullanmaktadır. Piksel çiftleri arasında korelasyonu elde etmek için polinom terimlerini (ikinci derece) kullanan bu algoritmada, boyut normalleştirilmesi ile bir karakter görüntüsü, $(n \times n)$ 'lik binary görüntüsüne dönüştürülür. Yani bu görüntü, $n \times n = N$ elemanlı vektör olarak temsil edilebilir:

$$\mathbf{v} = \mathbf{v}_0, \mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_{N-1}, \quad \mathbf{v}_i = 0 \text{ veya } 1 \text{ 'dir.} \quad (3.39)$$

$\mathbf{v}$ 'nin bileşenleri, M elemanlı $\mathbf{x}$ özellik vektörünü yaratmak için polinom terimlerini (tipik olarak quadratik) üretir.


$$\mathbf{x} = \mathbf{f}(\mathbf{v}) = (f_1(\mathbf{v}), f_2(\mathbf{v}), \dots) \quad (3.40)$$

Ayrılacak K adet sınıf varsa, K -boyutlu diskrimnant vektörü $\mathbf{d} = (d_0, d_1, d_2, \dots, d_{K-1})$ oluşturulur.

$$d_i = a_{i0}x_0 + a_{i1}x_1 + \dots + a_{iM-1}x_{M-1} \quad (3.41)$$

Her d_i , $\mathbf{x}$ bileşenlerinin lineer açılımıdır ve böylece $\mathbf{v}$ 'nin bileşenlerinin polinom ifadesi olur. Buradan $\mathbf{d} = \mathbf{A} \cdot \mathbf{x}$ yazılabilir ve $\mathbf{A}$ katsayılar matrisi en küçük kareler yöntemine göre hesaplanır. Bu matris hesaplandıktan sonra $\mathbf{v}$ test görüntüsü için polinom diskrimnant fonksiyonu sınıflandırma için değerlendirilebilir.

Olasıcı Sinir Ağları (Probabilistic Neural Networks) birçok sinir ağı modelinden (geri yayılma v.b.) daha çabuk öğrenmektedir (Specht, 1992). Farklı uygulama alanlarında başarıyla uygulanan sinir ağı türüdür. Olasıcı sinir ağı, 'durum' olarak adlandırılan örnekler grubunun oluşturduğu bir deneme setinden öğrenir. Her durum kendi giriş vektörüne ve sonuç sınıflara sahiptir. Uygulama esnasında, sinir ağı ek giriş vektörlerini (x) alır ve en çok benzediği sınıfın sonuç değerini oluşturur (Şekil 3.17).



Şekil 3.17 - Olasıcı sinir ağı yapısı (Martinez, 1997)

Deneme seti içindeki her çalıştırma durumu için bir gizli düğüm vardır. Her gizli düğüm (h_i), merkezindeki giriş noktası ile bağlantılı olup bunlar giriş vektörünü oluşturur. Ağ içindeki her bağlantı 1 ağırlığına sahip olur, bunun anlamı giriş vektörünün doğrudan gizli düğüme geçtiğidir. Ağ içindeki her gizli (h_i) düğüm tek bir sınıf düğümüne (s_j) bağlanmıştır. Her sınıf düğümü de; gizli düğümlerin etkinliklerinin toplamını hesaplamaktadır. Bu toplam da karar düğümüne geçer ve karar düğümü de en yüksek toplam etkinliğe sahip sınıfı sonuç olarak seçer.

Bu ağ modelinin en önemli üstünlüklerinden birisi, herhangi bir iterasyonlu çözüme gerek duymaması ve bu nedenle çabuk öğrenmesidir. Buna karşın en büyük dezavantajı, her çalıştırma durumunda bir gizli düğüme sahip olması ve hesaplama için daha çok hafıza ve zamana gereksinim duymasındır. Fazla sayıda gizli düğüme sahip olma eğiliminin yarattığı problem için genel bir çözüm; ağ kurulurken orijinal deneme seti içinde yalnızca rastgele seçilmiş bir altgrubun sabit tutulmasıdır. Bu bağlamda oluşturulan/ önerilen sinir ağı yapılarına "indirgenmiş- olası sinir ağı" denilmektedir (Martinez, 1997).

İstatistiksel veri analizinde kullanılan standart lineer tekniklerden birisi de Fisher diskriminant analizidir. Lineer yöntemlerin sınırlı oluşu nedeniyle daha genel sınıf ayrılabilirlik kriteri elde etmek için Fisher diskriminant yöntemini esas alan non- lineer

sınıflandırma teknikleri önerilmektedir (Shashua, 1999). Yapay sinir ağı bağlamında düşünüldüğünde, Fisher diskriminant analizin 'perceptron' sinir ağı modeline çok benzediği görülebilir. Sınıflandırma problemlerinde sınıfları (c_i) ayırdedebilmek için lineer bir fonksiyon arandığında, bu fonksiyon

$$\omega X_i + c > 0 \rightarrow \begin{cases} c_1 \text{ seçilir} \\ \text{değilse } c_2 \end{cases} \quad (3.42)$$

olarak yazılabilir. Bu noktada önemli olan ağırlıkların nasıl seçileceğidir. Ağırlıklar, her sınıfın ortalama vektörlerinin ayrılabilirliğini enbüyük yapacak şekilde bir strateji uygulanarak seçilecektir. İki farklı sınıfın örnekleri $X_1 = \{x_1, \dots, x_{l_1}\}$ ve $X_2 = \{x_1, \dots, x_{l_2}\}$ olarak gösterilirse; Fisher lineer diskriminant, aşağıdaki bağıntıda tanımlanan değeri enbüyük yapan ağırlık vektörü olarak tanımlanır:

$$J(w) = \frac{w^T S_B w}{w^T S_W w} \quad (3.43)$$

Burada S_B ve S_W sırasıyla sınıf dağılımları arasında ve içindeki vektörleri (kovaryans) gösterir:

$$S_B = (m_1 - m_2)(m_1 - m_2)^T \quad (3.44)$$

$$S_W = \sum_{i=1,2} \sum (x - m_i)(x - m_i)^T ; \text{burada } m_i = \frac{1}{l_i} \sum_{j=1}^{l_i} x_j^i \quad (3.45)$$

Burada $J(w)$ ' yi maksimum yapma fikri, izdüşürülen sınıf ortalamalarını maksimum yaparken (pay), o doğrultudaki sınıfların varyansını minimum yapan (payda) bir doğrultu aramaya dayanır. Buradan ağırlıkların ölçeğinin önemli olmadığı, doğrultunun (yön) önemli olduğu sonucuna ulaşılabilir. Yukarda iki sınıf için ele alınan ifadeler kolaylıkla çoklu sınıflara genelleştirilebilir.

Sınıflandırma problemlerinde sınıfları birbirinden ayırdedebilmek için hangi özellik (veya özellikler grubu) nun daha iyi olduğuna karar verilirken, klasik yaklaşım optimal Bayes yönteminden başlayarak quadratik veya lineer diskriminant analiz yöntemlerine kadar geniş bir alanı kapsar. Sınıfların soncul olasılıklarının bilinmemesi nedeniyle normal dağılım varsayımı altında quadratik diskriminant analize ulaşılır (bu bir bakıma sınıf merkezli bir modelin-pattern Mahalanobis uzaklık ölçüsüdür). Tüm sınıflar için eşit kovaryans yapısı varsayılarak quadratik diskriminant analiz lineer hale gelir. Anılan bu varsayımlara rağmen Fisher diskriminant analiz

“güçlü” bir yöntem olduğu kanıtlanmıştır. Bunun bir nedeni, lineer bir model olarak “bozunum (noise)” değerlerine karşı oldukça kesin bir tahmin yöntemi olmasıdır. Ayrıca pratikteki sınıflandırma uygulamalarında lineer diskriminantın yeterince kompleks olmadığı gözönüne alınarak, Fisher diskriminantın non- lineer genelleştirilmesine dayanan yöntemler (Support Vector Machines, kernel algoritmaları v.b.) de önerilmektedir (Schölkopf ve diğ., 1999; Smola ve diğ.,1998). Tez kapsamında hem “perceptron” sinir ağı modeline benzerliği hem de non- lineer genelleştirme özelliği nedeniyle görüntü sınıflandırma uygulamalarında Fisher diskriminant algoritması kullanılacak ve performansı incelenecektir.



4. YAPAY SINIR AĞI KULLANARAK GÖRÜNTÜ SINIFLANDIRMASI VE DOĞRULUK DEĞERLENDİRMESİ- UYGULAMALAR

Bu bölümde klasik- parametrik sınıflandırma algoritmaları ve daha önceki bölümlerde açıklanan yöntemler ve algoritmalar kullanılarak, seçilen bir uydu görüntüsü üzerinde sınıflandırma yapılarak elde edilecek bulgular karşılaştırılacak ve ayrıca önerilen yeni algoritmaların (yapay sinir ağı tasarımı ve doğruluk tahmin yöntemi) uygulama üzerindeki performansı değerlendirilecektir.

4.1. Problemin Tanımlanması

Uygulamalarda kullanılacak sinir ağı algoritmasını kısaca açıklamak gerekirse, N banddan oluşan H multispektral veri setini ele alalım. (m farklı özellik türleri ve c_i sınıfları gösterebilir.) T örnekleme setini (training set) de oluşturmak gerekir. Bu veri seti her özellik türü için $n_i c_i$ örneklerine sahip olur.

$$T = \{s_1c_1, s_2c_1, \dots, s_{n_1}c_1, \quad s_1c_2, s_2c_2, \dots, s_{n_2}c_2, \quad \dots \quad s_1c_m, s_2c_m, \dots, s_{n_m}c_m\}, \quad (4.1)$$

Burada s_{kj} :j.inci sınıfın k örneğini gösterir ve N boyutlu bir nokta olur. Bu veri seti noktaların toplam sayısını içerir.

$$N_p T = n_1c_1 + n_2c_2 + \dots + n_m c_m, \quad (4.2)$$

Çalıştırma (training) işlemi W_i ağırlık matrislerinin hesabını gerektirmektedir. Hata fonksiyonunu minimum yapacak şekilde $E(W_0, W_1, \dots, W_{n-1}) = \min$. ağırlık matrisleri hesabı yapılacaktır.

$$E(W_0, W_1, \dots, W_{n-1}) = (d - O)^T (d - O) \quad (4.3)$$

d : istenen sonuç vektörü, ve O : ağ sonuç vektörüdür. O sonuç vektörü, W_i ağırlık matrisi ile X_i gizli tabakaların bir fonksiyonudur.

$$O = F[W_{n-1}X_{n-1}] \quad (4.4)$$

X_{n-1} : (n-1).inci gizli tabaka sonuçları ve $F[]$ elemanları etkinlik fonksiyonu ile belirlenen diagonal matristir. Ağ içindeki her tabaka şu eşitlikle tanımlanabilir :

$$X_k = F[W_{k-1}X_{k-1}] \quad (4.5)$$

X_0 giriş tabakası, ve X_1 ilk gizli tabakadır, ve $X_1 = [W_0X_0]$ olur. Benzer olarak ikinci gizli tabaka $X_2 = F[W_1X_1]$ olarak tanımlanır. O çıkış tabakası olduğu için X_n 'e eşit olacaktır.


$$X_n = O = F[W_{n-1}X_{n-1}] \quad (4.6)$$

$$\text{Ağırlık matrisleri ise; } W_{k+1} = W_k - \eta \nabla E(W_0, W_1, \dots, W_{n-1}) \quad (4.7)$$

ile bulunur. $0 < \eta < 1$ dir ve η : öğrenme parametresidir. $\nabla E(W_0, W_1, \dots, W_{n-1})$ hata fonksiyonunun gradyenidir. (k+1) sistemin iterasyon sayısıdır. Ağırlık matrisleri güncelleştirildikten sonra H seti içinden ci sınıfları belirlenecektir (Bosch, 1994).

4.2. Uzaktan Algılamada Görüntü Sınıflandırmasının Doğruluk Değerlendirmesi

Uzaktan algılama uzmanlarının üzerinde en çok durdukları konulardan biri de sınıflandırma doğruluğu değerlendirmesidir. Doğruluk değerlendirmesinde çok kullanılan yöntem hata matrislerinin (confusion matrix, contingency table) hazırlanmasıdır. Hata matrisleri sınıf bazında referans verileri (gerçek -yersel veriler) ile otomatik sınıflandırma sonuçları arasındaki ilişkiyi karşılaştırır (Şekil 4.1).



Şekil 4.1: Hata matrisinin şematik gösterimi

Şekilde matristeki değerler piksel sayısını göstermektedir. Hata matrisi genel olarak referans (gerçek) ve değerlendirilen görüntülerin karşılaştırma sonuçlarını ortaya çıkarmaktadır. Matrisin sütun elemanları örnekleme veri setine ilişkin değerleri gösterirken, satır elemanları sınıflandırılmış piksel verilerini göstermektedir. Doğru arazi örtüsüne sınıflandırılmış örnekleme veri seti pikselleri ana köşegen (diagonal) üzerinde bulunmaktadır.

Hata matrislerinden çeşitli sınıflandırma doğruluk kriterleri türetilebilir (Congalton ve Story, 1986). Sık kullanılan “toplam doğruluk” (overall accuracy) terimi, doğru biçimde sınıflandırılmış piksellerin toplam sayısının (köşegen toplamı) referans piksellerin toplam sayısına bölünmesiyle elde edilir. Matrisin köşegeni üzerinde bulunmayan (non-diagonal) elemanları “ihmal hatası” (omission error) veya “dahil etme hatası” (comission error)’ nı temsil eder.

“Üretici doğruluğu” (producer’s accuracy), her sınıf içinde doğru olarak sınıflandırılmış piksellerin sayısını, bu sınıf için kullanılan örnekleme veri seti pikselleri sayısına bölerek bulunur ve verilen bir arazi-örtü türünün örnekleme seti piksellerinin ne kadar iyi sınıflandırılabilirdiğini gösterir.

“Kullanıcı doğruluğu” (user’s accuracy), her sınıf içinde doğru sınıflandırılmış piksel sayısını, bu kategori içinde sınıflandırılan piksellerin toplam sayısına bölünmesiyle bulunur ve “dahil etme hatası”nı gösteren bir ölçüdür. Bu değer de verilen bir sınıfa atanan bir pikselin bu sınıfı gerçekte temsil etme olasılığını gösterir.

Sınıflandırma doğruluğunun yorumlanmasında ilginç bir nokta, piksellerin sınıflara tamamen ve rastgele atanması durumunda bile, hata matrisinde yüzdesel olarak ve tesadüfi doğru değerler üretebilmesidir. Kappa ($\hat{k}$) istatistik ölçüsü, referans verilerle otomatik- sınıflandırılmış veriler arasındaki gerçek uyum ile, yine referans verilerle rastgele sınıflandırılmış veriler arasındaki şans uyumu arasındaki farkı göstermek için kullanılmaktadır (Stehman, 1996). Kavramsal olarak;

$$\hat{k} = \frac{\text{gözlenendoğruluk} - \text{şans uyumu}}{1 - \text{şans uyumu}} \quad (4.8)$$

Bu istatistik, hata matrisindeki doğru değerlerin tesadüfen uyuma karşı, gerçek uyumun neden olabilmesinin göstergesidir. İdeal durumda gözlenen uyum 1’e, şans uyumu sıfıra yaklaşır ve kappa değeri 1 olur. Pratikte $0 < \hat{k} < 1$ dir. Sözel olarak ifade etmek gerekirse; örneğin kappa değeri 0.75 ise, gözlenen sınıflandırma doğruluğu

rastgele sonuçlanacak bir sınıflandırma doğruluğundan %75 daha iyi olduğu anlamına gelir. Hata matrisinden kappa değeri şu eşitlikle hesaplanabilir:

$$\hat{k} = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} x_{+i})} \quad (4.9)$$

Bağıntıda geçen r : hata matrisinde satır sayısı, x_{ii} :köşegen üzerindeki gözlem sayısı, x_{i+} : i satırındaki gözlemlerin toplamı, x_{+i} : i sütunundaki gözlemlerin toplamı ve N : matris içindeki gözlemlerin toplam sayısıdır. Buradan anlaşılacağı üzere, Kappa istatistiği, köşegen üzerinde bulunmayan elemanları da doğruluk değerlendirmesine katmaktadır. Kappa istatistiğinin temel avantajlarından biri de; verilen bir hata matrisinin veya matrisler arasındaki farkların istatistiksel anlamlılığını (signifikans) belirlemek için kullanılabilmesidir. Sözgelimi farklı tarihlerdeki uydu görüntülerinin sınıflandırma sonuçlarının karşılaştırılmasında veya *farklı sınıflandırma teknikleri* ile gerçekleştirilen sınıflandırma doğruluklarının karşılaştırılması için kullanılabilir. Bu nedenle tez kapsamında, klasik sınıflandırma algoritmalarıyla ve yapay sinir ağı teknikleri ile yapılan sınıflandırmaların doğruluklarının karşılaştırılmasında kappa istatistiğinden yararlanılacaktır.


4.3. Uygulama Örnekleri- Landsat TM Görüntü Verilerinin Sınıflandırılması

Bu bölümdeki çalışmada, seçilen bir uydu görüntüsünün klasik- standart sınıflandırma algoritmaları ve yapay sinir ağı teknikleri kullanılarak sınıflandırılması, görüntü sınıflandırması doğruluk değerlendirmesi yapılarak sonuçların karşılaştırılması; bunlara ek olarak daha önce önerilen yeni sinir ağı doğruluk güven tahmini yöntemi gerçekleştirilerek uygun ağ tasarımı yapılması ve hızlı çözüm sağlamak üzere tasarlanan ağ algoritmasının performansının incelenmesi amaçlanmıştır.

Uygulamalarda 5 banddan (kanal) oluşan ve spektral (yansıma) değerleri $0.45 \mu\text{m}$ ile $1.75 \mu\text{m}$ arasında değişen bir multispektral veri seti (H) kullanılmıştır. Uydu görüntüsü 9 Eylül 1992 tarihli Landsat TM İstanbul (Boğaz bölümü) görüntüsüdür. (512x512 piksel) den oluşan görüntü ve altalanları görüntü sınıflandırması için kullanıldı (Ek A.1). Görüntü sınıflandırmasında, 7 ayrı sınıftan oluşacak şekilde örnekleme veri seti oluşturuldu. Otomatik arazi –örtü sınıflandırması için multispektral veri setine standart- parametrik yöntemler ve sinir ağı teknolojileri uygulanarak,

anılan yöntemler arasında kapasite ve performans yönünden karşılaştırma/ irdeleme yapılması amaçlanmıştır. Buna ek olarak, önerilen yeni sinir ağı doğruluk güven tahmini algoritması yardımıyla uygun ağ tasarımı yapılması ve hızlı çözüm sağlamak üzere tasarlanan yeni sinir ağı yönteminin (ve yazılımı) incelenmesi hedeflenmiştir.

Geriyaılma algoritmasının dezavantajlarını gidermek amacıyla tasarlanan HYSA (Hızlı Yapay Sinir Ağı) yazılımı için örnekleme bölgesi ve altgruplarına ait piksel grupları deneme setleri olarak seçilmiş ve çeşitli (ve farklı) yapılarıdaki ileri- itimli sinir ağlarına uygulanmıştır (Şekil 4.2).



Şekil 4.2- HYSA Yazılım Menüsü

Yazılım yalnızca ileri- itimli (feedforward) sinir ağı mimarisi için tasarlanmıştır. Sınıflandırma problemi ile ilgili giriş değerleri (piksel değerleri) ve test seti hedef verileri bir dosyaya kaydedildiğinde, yazılım açıklanan algoritmaya göre çalıştırma işlemine başlamaktadır. Kullanıcı ağ yapısını ve parametreleri (nöron sayısı, tabakalar, transfer fonksiyonu,..vb.) tanımlayabilmekte, ayrıca çalıştırma esnasında sonuç değerleri ile ağırlıkların tablolar ve grafik sunumları kolaylıkla gerçekleştirilebilmektedir.

Model Dosya Tipi

Model dosya: C:\HYSA\ORNT10.DAT SEÇ..

Tabakaların Tanımlanması

	isim	kol.	ölçek	ara
Giriş Tabakası	1	i1	1	0
	2	i2	2	1
	3	i3	3	1
Çıkış Tabakası	1	o1	4	0
	2	o2	5	1
	3	o3	6	1
	4	o4	7	1

Giriş ekle Çıktı ekle OK

Şekil 4.3- Sınıflandırma model dosya tipi

Sınıflandırmada kullanılacak model dosyası, deneme setine ait piksel verileri (giriş tabakası) ve ağ sonuç tabakası değerlerini içermekte ve tabakaların tanımlanabilmesini sağlamaktadır (Şekil 4.3). Ayrıca farklı ağ mimarisi seçilebilmekte

MLP Ağ Mimarisi

	Düğüm sayısı	Transfer fonksiyonu
Giriş tab.	3	3
Gizli tabaka	4	1
Çıkış tabaka	7	3

**1 - Sigmoid fonk. [0-1]
2 - Simetrik logaritmoid
3 - Lineer
4 - Sigmoid fonk[-1 ve 1]**

Seçenekler Sabit-eşit ağırlıklar Kapat

Şekil 4.4- Ağ mimarisi seçimi menüsü

, tabakalardaki nöron sayıları ve çok kullanılan bazı transfer fonksiyonları bu tabakalara atanabilmektedir (Şekil 4.4). Aynı tabakalar için farklı transfer fonksiyonlarının tanımlanabileceği unutulmamalıdır. Çözüm algoritması ile ilgili ağ

parametreleri (iterasyon sayısı, karesel ortalama hata sınırı, kısmi türevlerin kullanılması, parametrelerdeki sınır değişimler,..vb.) istenildiğinde değiştirilebilmektedir (Şekil 4.5).


Şekil 4.5- Sinir ağı işlem seçenekleri

Belirlenen parametre seti ve giriş verileri yardımıyla ağı çalıştırıldığında, algoritma parametreleri (iterasyon sayısı, karesel ortalama hata, düzeltmelerin kareleri toplamı ve Marquardt parametresi) dosyaya yazdırılabilmektedir (Şekil 4.6).

Yazılımla elde edilen çözümün, geriyayılma algoritmasından çok daha hızlı olduğu görülmüştür. Sıklıkla kullanılan geriyayılma algoritmasının veri miktarı kısıtlı olduğu zaman iyi sonuç vermediği, ayrıca lokal minimum değerine yakalanma riskinin yüksek olduğu da hatırdan çıkarılmamalıdır. Söz konusu sakıncaları gidermek için önerilen yöntem (yazılımla), daha az sayıda iterasyon ve yüksek doğrulukla hata yüzeyinin minimum bölgesine ulaşmakta ve optimum ağı ağırlık değerlerini hesaplayabilmektedir.

Seçilen görüntünün altalanları sinir ağı yazılımının deneme setleri olarak kullanılmış ve sınıflandırılmıştır. Seçilen örneklerden bir tanesi (259x260 piksel) Şekil 4.7a' da gösterilmektedir. Aynı görüntü parametrik bir yöntemle de sınıflandırılmıştır. Standart parametrik yöntemlerden en çok kullanılan (popüler) yöntem en çok benzerlik yöntemi olduğu için bu sınıflandırma tekniği kullanılacaktır. Burada unutulmaması gereken nokta, farklı sinir ağı mimarileri kullanılarak yapılan sınıflandırmaların

doğruluklarının da değişebileceğidir. Bu nedenle yeterli miktarda deneme yapılmadan ve istenen doğruluk değerlerine ulaşılmadan nihai karara varılmamalıdır.



HYSA Değerler

Edit


05-23-2001 21:56:12
Kur dosyası : C:\HYSA\ORN\Y1.MLP
Model dosyası : C:\HYSA\ORN\T10.DAT

Zaman	itrs.	Dkt	koh	Marq.
21:56:12	0000	2.282e-03	1.280e-03	1e-02
21:56:13	0001	8.820e-06	7.957e-05	1e-03
21:56:14	0002	8.104e-10	7.627e-07	1e-04
21:56:15	0003	1.819e-16	3.614e-10	1e-05
21:56:16	0004	1.541e-16	3.327e-10	1e-06
21:56:17	0005	1.390e-16	3.159e-10	1e-06
21:56:18	0006	1.270e-16	3.020e-10	1e-07
21:56:19	0007	6.750e-17	2.201e-10	1e-07
21:56:20	0008	4.720e-17	1.841e-10	1e-07
21:56:20	0009	3.598e-17	1.607e-10	1e-07
21:56:21	0010	2.864e-17	1.434e-10	1e-07
21:56:22	0011	2.346e-17	1.298e-10	1e-07
21:56:23	0012	1.963e-17	1.187e-10	1e-07
21:56:24	0013	1.671e-17	1.095e-10	1e-07
21:56:25	0014	1.441e-17	1.017e-10	1e-07
21:56:26	0015	1.257e-17	9.501e-11	1e-07
21:56:27	0016	1.108e-17	8.918e-11	1e-07
21:56:28	0017	9.840e-18	8.405e-11	1e-07

Liste tipi Yenile Kapat

Şekil 4.6- Çözüm algoritması değerlerinin görünümü

Seçilen görüntünün parametrik sınıflandırması için Multispec Yazılımı kullanılmıştır. Sınıflandırmada doğruluk değerlendirmesi için bölüm başında açıklanan hata matrisinden yararlanılacaktır. Benzer şekilde görüntü üzerinde bir çok örnekleme alanı üzerinde (farklı veri büyüklükleri ile) sınıflandırma yapılmıştır.



Şekil 4.7a- HYSYA yazılımı ile sınıflandırılan görüntü

Sinir ağı yazılımında çözüm bulunduğu zaman ağ sonuç değerlerine göre sınıflar rakamlarla kodlanır ve sonuç görüntü oluşturulur.(1:deniz, 2:orman, 3:orman², 4:yollar, 5:yerleşim alanı,6:yerleşim alanı²) Şekil 4.7b' de sınıflandırılan görüntünün bir bölümü görülmektedir.

```

3 2 3 3 2 2 3 3 3 4 4 4 4 4 4 4 3 4 3 4 6 4 3 3 3 4 4 4 4 2 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 2 2 4 2 3 6 3 6 6 4 4 6 6 6
4 3 3 3 2 2 3 4 5 4 4 4 4 4 4 4 4 3 3 3 3 6 3 3 3 2 5 4 4 4 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 2 2 4 2 2 3 3 6 6 6 6 6 6 6
4 4 4 3 2 3 3 6 6 6 4 4 4 4 4 4 4 4 3 3 3 6 4 3 3 4 4 4 4 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 2 2 3 3 3 6 6 6 6 6 6 6
2 2 4 4 4 4 3 8 4 4 4 4 4 4 4 4 4 3 3 3 4 4 4 4 4 4 4 4 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 2 2 3 3 2 2 3 4 6 6 3 6 6 6 6
3 2 2 4 4 4 4 4 4 4 4 4 4 4 4 4 4 3 3 2 4 4 4 4 4 4 2 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 2 3 4 2 2 4 6 6 3 3 3 3 4 6
2 2 2 2 3 3 4 4 4 4 4 4 4 4 4 4 4 4 4 3 4 4 4 4 4 5 5 4 4 3 3 3 3 3 3 3 3 3 3 3 3 3 3 4 2 3 4 3 2 4 6 6 4 2 2 3 3
2 2 2 2 3 3 4 4 4 4 4 4 5 5 5 4 4 4 4 4 3 4 4 4 4 4 4 4 4 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 2 2 3 2 2 3 3 3 3 2 2 2 2
2 2 2 2 3 3 4 4 4 4 4 4 5 5 5 5 4 4 4 4 4 4 4 4 4 4 4 4 4 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 2 4 2 3 3 3 3 3 2 2 2 3
3 2 2 2 2 3 3 4 4 4 4 4 4 5 5 5 5 4 4 6 4 4 4 6 4 4 4 4 4 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 4 2 4 3 3 4 4 3 3 3 3 3
3 3 2 2 2 2 3 2 4 4 4 4 4 4 5 5 5 5 4 5 6 6 6 6 4 6 4 4 2 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 4 2 3 3 3 3 3 3 2 2 3
3 2 2 2 2 2 4 4 4 4 4 4 5 5 5 5 8 8 8 8 8 8 8 8 4 4 4 2 3 3 3 3 3 3 3 2 2 2 2 2 2 2 2 2 4 4 4 4 8 3 3 3 3 3 3 3 4 3 4 6
3 2 2 3 2 4 4 4 4 4 4 4 4 5 5 5 5 4 4 4 4 4 4 4 4 4 4 4 4 2 3 3 3 2 2 2 2 2 2 2 2 4 4 4 4 3 3 3 4 4 4 3 4 4 6 6 6 4
3 2 2 3 2 4 4 4 4 4 4 4 4 5 5 5 5 4 4 4 4 4 4 4 4 4 4 4 4 4 2 3 3 3 2 2 2 2 2 2 2 2 2 4 4 4 4 3 3 3 4 4 4 3 4 4 6 6 6 4
3 2 2 4 4 4 4 4 4 4 4 4 4 5 5 5 5 6 6 6 6 4 4 4 4 4 4 4 4 4 4 4 4 4 2 2 2 2 2 2 2 2 2 2 4 4 4 4 3 3 3 3 3 3 2 4 4 4 6 6 6 6
3 3 2 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 6
8 3 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 6
3 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 6
4 4 4 4 4 4 5 5 5 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 6
4 4 4 4 5 5 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4

```

Şekil 4.7b- HYSYA yazılımı ile sınıflandırılan görüntünün (kodlanmış) bir bölümü

Sinir ağı yazılımı ve ençok benzerlik sınıflandırma yöntemi ile elde edilen hata matrisleri Tablo 4.1 ve Tablo 4.2' de gösterilmektedir.


Tablo 4.1- Sınır açığı tekniği ile sınıflandırmada doğruluk değerlendirilmesi

	deniz	orman	orman ²	yollar	yerleşim	yerleşim ²	Toplam
deniz	55544	527	134	76	0	0	56281
orman	0	1345	172	93	51	0	1661
orman ²	0	0	1466	71	0	234	1771
yollar	0	0	0	1803	94	256	2153
yerleşim	134	0	0	312	2620	416	3482
yerleşim ²	0	0	95	0	213	1684	1992
Toplam Doğruluk : %95.72 Kappa kats.: 0,858							
Toplam	55678	1872	1867	2355	2978	2590	67340
Üretici D.(%)	99,76	71,85	78,52	76,56	87,98	65,02	
Kullanı.D.(%)	98,69	80,97	82,78	83,74	75,24	84,54	

Tablo 4.2- Ençok benzerlik yöntemi ile sınıflandırmada doğruluk değerlendirilmesi

	deniz	orman	orman ²	yollar	yerleşim	yerleşim ²	Toplam
deniz	54345	867	241	89	134	54	55730
orman	0	1965	234	136	0	43	2378
orman ²	0	0	1734	17	53	153	1957
yollar	63	0	0	1486	92	167	1808
yerleşim	249	176	0	216	2417	227	3285
yerleşim ²	124	0	78	0	246	1734	2182
Toplam Doğruluk : %94.56 Kappa kats.: 0,830							
Toplam	54781	3008	2287	1944	2942	2378	67340
Üretici D.(%)	99,20	65,33	75,82	76,44	82,15	72,92	
Kullanı.D.(%)	97,51	82,63	88,6	82,19	73,58	79,47	

HYSA yazılımı klasik geri yayılma algoritmasına göre daha hızlı çözüm sağlamıştır. Bu sonuca sözkonusu örnek için çizilen hata grafiğinden de kolaylıkla ulaşılabilir (Şekil 4.8). Geri yayılma algoritması kullanıldığında çok daha fazla iterasyon yapmak gerekmekte bu da çözüm zamanını artırmaktadır.



Şekil 4.8- Hata grafiği


Tüm görüntünün parametrik algoritmalarla sınıflandırılması için kullanılan profesyonel yazılımlardan ilki "**MultiSpec**" sayısal (digital) görüntü işleme yazılımıdır (Ek.A2). (Multispec Application Version 1.2 for Windows 95/98/NT. 4/2/1999. 32-bit version. Purdue Research Foundation. NASA Grants NAGW-925 and NAGW-3924.) Bu yazılımın orijinali ; 1960'lı yıllarda üretilen uzaktan algılama multispektral veri işleme sistemlerinin ilklerinden LARSYS'dir. Amerika'daki hükümet laboratuvarları ile üniversite araştırma laboratuvarlarında kullanılan yazılımlar ve birçok ticari üretim yazılım, bu yazılımdan doğmuştur. Hem multispektral hem de hiperspektral verilerin pratik, hızlı ve kolay analizinde kullanılıyor ve birçok görüntü format türünü destekliyor. (ERDAS, PDS,VICAR, GAIA, MacSADIE,...vb.) Multispec 200'den fazla spektral banddan oluşan verilerin gösteriminde kullanılabilir.

Görüntü sınıflandırılması için kullanılan diğer yazılım **PIT'** dir (Ek A.3). NASA tarafından geliştirilen bir yazılım. (NASA GSFC, USAF Academy.) Orijinali Unix işletim sisteminde çalışıyor, sonradan Windows 95/98/NT' a uyarlanmıştır. Yazılımın asıl kullanım alanı; görüntü sınıflandırmasıdır. (Landsat, AVHRR ,GOES,SPOT, AVIRIS, ve JERS uydu görüntülerini işleyebiliyor.) Gelişmiş, yetkin ve güncel sınıflandırma algoritmaları içeriyor. Bu tez içinde kullanılmasının nedeni ise; olası yapay sinir ağını (probabilistic neural network) bir görüntü sınıflandırma tekniği olarak kullanılıyor olmasıdır. Klasik sınıflandırma yöntemleri ile birlikte, anılan yazılımın "sınıflandırma menüsü"nde yer almış olması, yapay sinir ağlarının uzaktan algılama verilerinin sınıflandırmasında kullanılan standart bir araç olduğunu göstermesi bakımından ilginç bir örnektir.

Yapay sinir ağı uygulamalarında, geliştirilen HYSIA yazılımından başka bu alanda kendini kanıtlamış, profesyonel bir yazılımın kullanılması yararlı olacaktır. Bu yazılım **ThinksPro** 'dur (Ek A.4). (ThinksPro 1.05 – Neural Networks for Windows.1991-1995. Logical Designs Consulting Inc.) ThinksPro ; günümüzde popüler olan en yaygın ve gelişmiş sinir ağı algoritmaları ve mimarileri içermektedir. Ağın çalıştırılması aşamasında görsel araçlara sahiptir. Çalışma-tabloları ve grafik editöre sahip olduğundan, standart yazılımlara veri import/ export fonksiyonları sağlama özelliği vardır. Ağın çalıştırılması sırasında kullanıcı müdahalesine açık olması nedeniyle, ağın öğrenmesi/ yapısı ile ilgili opsiyonlara erişimi kolay ve esnek bir yapıdadır.

Ayrıca günümüzde çok çeşitli uygulama alanlarında başarılı bir şekilde kullanılmakta olan diğer bazı önemli yapay sinir ağları yazılımları (ticari olmayan yazılımlar Ek B.5 ve ticari yazılımlar Ek B.6' da) tez ekinde sunulmuştur.


Yapay sinir ağında uygun mimari seçimi yapılabilmesi için tek ve iki- gizli tabakaya sahip ileri-iterimli sinir ağları (kombinasyonları) kullanılacaktır. Görüntü sınıflandırması için sinir ağı üç giriş nöronu (3 band- 5,4 ve 1) ve yedi çıkış nöronundan (arazi örtü sınıfları) oluşacaktır (Şekil 4.9).



Şekil 4.9- Uygulamada kullanılan sinir ağı modeli


Burada nöron sayılarının aynı zamanda vektör boyutu olduğu unutulmamalıdır. Bu genel şematik gösterim iki-gizli tabakayı içermesine rağmen, tek gizli tabakaya sahip ağlar da uygulama için kullanılacaktır. Kullanılan sinir ağı yapılarını daha ayrıntılı göstermek üzere yeni bir tablo düzenlenebilir (Tablo 4.3).

Tablo 4.3- Uygulamada kullanılan sinir ağı mimarileri




Tablo 4.3' te sınıflandırma uygulamalarında kullanılan sinir ağı yapıları gösterilmektedir. Tablonun sol kısmı tek tabakalı sinir ağı yapılarına, sağ tarafı ise iki tabakalı sinir ağı yapılarına ayrılmıştır. Tablonun solunda yer alan XO, X1 ve X2=O (üç sütun), tek tabakalı sinir ağının tabakalarını temsil etmektedir. XO giriş tabakasını, X1 gizli tabakayı ve X2 de çıkış tabakasını temsil etmektedir. Örnek olarak bu bölümün ilk satırında yer alan (3-4-7) yapısı; giriş tabakasında 3 nöronun, gizli tabakada 4 nöronun ve çıkış tabakasında ise 7 nöronun yer aldığını göstermektedir. Böylece tablodaki her satır, aslında farklı bir sinir ağı mimarisini göstermektedir ve her biri teker teker sınıflandırma uygulamasında kullanılacaktır.

Tablonun sağında yer alan bölümde ise 4 sütun görülmektedir. Burada XO, X1, X2 ve X3=O, iki- tabakalı sinir ağının tabakalarını temsil etmektedir. XO giriş tabakasını, X1 ve X2 gizli tabakaları ve X3 de çıkış tabakasını temsil etmektedir. Örnek olarak bu kısmın ilk mimarisinde (3-3-4-7); giriş tabakası 3 nöron, gizli tabakalar 3 ve 4 nöron ve çıkış (sonuç) tabakası da 7 nöron oluşmaktadır. Böylelikle tabloda yer alan her sinir ağı yapısı çalıştırılarak sınıflandırma yapılmıştır. Çalıştırılan bu sinir ağı yapılarından hangisinin (veya hangilerinin) doğruluk açısından güvenilir olduğuna karar vermek için ise; tez kapsamında önerilmiş olan yeni güven tahmin yöntemi ve yazılımı kullanılmıştır (Şekil 4.10).



Şekil 4.10- Yapay Sinir Ağlarında Güven Tahmini Yazılımı



Şekil 4.11- Güven Değeri Hesaplama Menüsü

Çalıştırılan ve öğrenmesi tamamlanan sinir ağı sonuç değerlerinden yararlanarak sinir ağı doğruluk güven tahmin değerlerinin hesaplanması için kullanılan yazılım menüsü Şekil 4.11' de görülmektedir. Görüntü sınıflandırması için kullanılan çeşitli sinir ağı mimarileri/ kombinasyonlar için belirlenen bir güven düzeyinde hesaplanan güven tahmin değerleri Tablo 4.4' te verilmiştir.

Tablo 4.4- Kullanılan sinir ağı yapıları için güven tahmin değerleri tablosu

Sinir Ağı	Hata Sınırı	Güven	Gözlem Sayısı	Örnek	Güven Aralığı	Karar
Yapısı	(Ağ Hatası)	Düzeyi	(Test Noktası)	Büyüklüğü	Üst Sınırı	
3-4-7	0.05	%95	18	250	0.1114	Reddedilir
3-5-7	0.05	%95	15	241	0.1006	Reddedilir
3-6-7	0.05	%95	8	265	0.0586	Kabul
3-7-7	0.05	%95	13	234	0.0931	Reddedilir
3-3-4-7	0.05	%95	21	319	0.0931	Reddedilir
3-3-5-7	0.05	%95	18	354	0.0792	Reddedilir
3-3-6-7	0.05	%95	7	327	0.0436	Kabul
3-3-7-7	0.05	%95	9	340	0.0496	Kabul
3-4-5-7	0.05	%95	5	178	0.0643	Reddedilir
3-4-6-7	0.05	%95	11	276	0.0702	Reddedilir
3-4-7-7	0.05	%95	20	268	0.1129	Reddedilir
3-5-5-7	0.05	%95	6	271	0.0476	Kabul
3-5-6-7	0.05	%95	14	272	0.0848	Reddedilir
3-5-7-7	0.05	%95	11	268	0.0722	Reddedilir
3-6-7-7	0.05	%95	7	274	0.0519	Kabul
3-7-7-7	0.05	%95	16	320	0.0799	Reddedilir

Sinir ağları doğruluklarının kestirilmesinde istatistik teorisine dayalı bir yaklaşım önerilmiştir. Bu teknik yardımıyla, çalıştırılan bir sinir ağının önceden belirlenen bir hata sınırı içinde ve güven düzeyinde, ağın sonuç değerlerini kullanarak istatistiksel anlamda ağın kabul edilebilirliği üzerinde bir test ölçütü oluşturulmaktadır. Örnek olarak tabloda ilk (3-4-7) sinir ağında , (%95 güven düzeyinde hedeflenen ve gerçekleşen ağ sonuçları arasındaki fark 0.05'i geçmeyecek şekilde tasarlanan sinir ağında) deneme setinden rastgele 250 örnek seçilmiş ve bu örnek seti içinden 18 adet noktada hata sınırı değerini aşmış olduğu görülmüş ve bu değerlere göre yazılım yardımıyla hesaplanan güven aralığı değerinin (%11) istenen değeri aşması (%5) nedeniyle ağ yapısının reddedilmesine karar verilmiştir. Bu şekilde çalıştırılan her bir sinir ağı modelinin kabul edilebilirliği test edilmektedir. Tablo 4.5' te ise %90 güven düzeyinde ve farklı deneme setlerine göre hesaplanan güven tahmin değerleri görülmektedir.


Tablo 4.5- Aynı ağ yapılarının farklı veri setlerine göre hesaplanan tahmin değerleri

Sinir Ağı Yapısı	Hata Sınırı (Ağ Hatası)	Güven Düzeyi	Gözlem Sayısı (Test Noktası)	Örnek Büyüklüğü	Güven Aralığı Üst Sınırı	Karar
3-4-7	0.05	%90	16	223	0.1069	Reddedilir
3-5-7	0.05	%90	16	243	0.0983	Reddedilir
3-6-7	0.05	%90	7	274	0.0475	Kabul
3-7-7	0.05	%90	16	255	0.0937	Reddedilir
3-3-4-7	0.05	%90	8	147	0.0960	Reddedilir
3-3-5-7	0.05	%90	15	317	0.0726	Reddedilir
3-3-6-7	0.05	%90	9	312	0.0498	Kabul
3-3-7-7	0.05	%90	14	434	0.0499	Kabul
3-4-5-7	0.05	%90	17	453	0.0557	Kabul
3-4-6-7	0.05	%90	9	307	0.0506	Kabul
3-4-7-7	0.05	%90	16	231	0.1033	Reddedilir
3-5-5-7	0.05	%90	7	273	0.0476	Kabul
3-5-6-7	0.05	%90	6	164	0.0709	Reddedilir
3-5-7-7	0.05	%90	10	196	0.0850	Reddedilir
3-6-7-7	0.05	%90	5	183	0.0566	Kabul
3-7-7-7	0.05	%90	12	267	0.0718	Reddedilir

Yazılımda ayrıca, seçilen deneme (örnekleme) seti çok büyük olduğu zaman kullanılmak üzere "Poisson dağılımı" hesabına da yer verilmiştir. Deneme setine oranla test noktası (gözlem sayısı) çok küçük kaldığı zaman Poisson dağılımı, Binom yaklaşımına oranla daha doğru bir yaklaşım olmaktadır.

Açıklanan şekilde istatistiksel olarak test edilen sinir ağlarından kabul edilebilir olanlardan, ayrıca görüntü sınıflandırması doğruluk değerlendirmesi yapılarak en yüksek doğruluğu veren sinir ağı (optimum) yapısı seçilir.

Görüntü sınıflandırması için parametrik yöntemlerden en çok benzerlik yöntemine göre yapılan sınıflandırma sonucu (Şekil 4.12) ve doğruluk değerlendirmesi (Tablo 4.6) aşağıda gösterilmektedir.



Şekil 4.12- En çok benzerlik yöntemine göre sınıflandırılmış görüntü

Tablo 4.6- En çok benzerlik yöntemiyle sınıflandırmada doğruluk değerlendirilmesi


	Orman	Yollar	Yerleşim Alanı	Deniz	Boş alan	Orman ⁽²⁾	Yerleşim Alanı ⁽²⁾	Toplam
Orman	41945	0	240	0	0	0	1071	43256
Yollar	0	29985	2817	0	0	0	457	33259
Yerl. Alanı	0	0	52483	0	0	850	6047	59380
Deniz	350	0	132	26534	0	0	0	27016
Boş alan	0	0	0	0	4524	0	140	4664
Orman ⁽²⁾	0	412	0	0	0	25335	2710	28457
Yerl. Alanı ⁽²⁾	203	0	12237	0	0	0	53672	66112
	Toplam Doğ. : 89.5 (%)				Kappa katsayısı : 0.871			
Toplam	42498	30397	67909	26534	4524	26185	64097	262144
Üretici D.(%)	98,7	98,64	77,28	100	100	96,75	83,73	
Kullanıcı D.(%)	96,97	90,16	88,38	98,22	97	89,03	81,18	

Aynı görüntü yapay sinir ağı kullanılarak (ThinksPro yazılımı ile) ve doğruluk güven tahmini yapılarak sınıflandırıldığında (uygun mimari ile) daha yüksek sınıflandırma doğruluğu elde edilmiştir. Sinir ağı normal geri yayılma algoritması ile çalıştırıldığında 12000 iterasyon sonrası çözüme ulaşmış ve karesel ortalama hata değeri 0.0073078 olmuştur. Bu şekilde sinir ağı sınıflandırma işlemi toplam 45 dakika sürmüştür. Buradan da anlaşılabacağı üzere sinir ağı sınıflandırma yönteminin temel dezavantajı öğrenme aşamasının çok zaman gerektirmesidir. Tablo 4.7’de ise sinir ağı ile sınıflandırılmış görüntünün doğruluk değerlendirilmesi görülmektedir.

Table 4.7 – Yapay sinir ağı ile sınıflandırmada doğruluk değerlendirilmesi

	Orman	Yollar	Yerleşim Alanı	Deniz	Boş alan	Orman ⁽²⁾	Yerleş. Alanı ⁽²⁾	Toplam
Orman	42543	0	54	0	0	30	629	43256
Yollar	0	31149	1716	0	0	76	318	33259
Yerleş. Alanı	0	22	56824	0	0	431	2103	59380
Deniz	77	0	86	26853	0	0	0	27016
Boş Alan	0	0	0	0	4596	0	68	4664
Orman ⁽²⁾	0	253	0	0	0	27243	961	28457
Yerleş. Alanı ⁽²⁾	35	0	7902	0	11	0	58164	66112
	Toplam doğruluk :94,4 %				Kappa katsayısı : 0.931			
Toplam	42655	31424	66582	26853	4607	27780	62243	262144
Üretici D.(%)	99,74	99,12	85,34	100	99,76	98,07	93,45	
Kullan.D.(%)	98,35	93,65	95,69	99,4	98,54	95,73	87,98	

Tablodan görüleceği üzere yapay sinir ağı ile sınıflandırılan görüntünün doğruluğu en çok benzerlik yönteminden (parametrik algoritma) daha yüksektir. Yapay sinir ağı ile sınıflandırılan görüntü ise Şekil 4.13’ te görülmektedir. Ayrıca yapay sinir ağı sınıflandırmasında kullanılan örnekleme bölgeleri (Ek B.1), yazılımın sinir ağı giriş menüsü ve sinir ağı kurulum- setup menüsü (Ek B.2) gösterilmektedir. Ağın çalıştırma seçenekleri (parametreler) ve veri seti test etme menüsü (Ek B.3)’ te gösterilmiştir. Ayrıca ağın çalışma esnasında sinir ağı yazılımının görünümü ise Ek B.4’ te verilmektedir.



Şekil 4.13- Yapay sinir ağı sınıflandırma görüntüsü

Geri yayılma algoritmasının daha önceki bölümlerde açıklanan dezavantajları nedeniyle, daha hızlı çözüm sağlayacak algoritmalar araştırılmış ve "Quickpropagation" algoritmasının kullanılmasına karar verilmiştir. Bu algoritma ağırlıkların optimum setini bulmak ve gerekli zamanı azaltmak için bazı *teknikler* geliştiren bir kontrollü öğrenme algoritmasıdır. Bu *teknikler* yardımıyla öğrenme işlemini hızlandıran durumların tesbiti yapılmaktadır. Geri yayılma algoritmasından farklı olarak ağırlıkların birbirinden bağımsız olduğu varsayılır. Diğer bir önemli özelliği ise hata yüzeyinin quadratik yüzey olduğunun (parabolik) varsayılmasıdır. Bu da hata fonksiyonunun global minimum değerinin bulunmasını kolaylaştırmaktadır. Bu algoritmanın parametreleri ise; *başlangıç öğrenme oranı* (ϵ : parabolik yüzeyden aşağıya doğru küçük bir itme etkisi yaratır), *en büyük adım sayısı* (Mu: adım

sayısının çok hızlı büyümesini engellemek için), *çekme faktörü* (Δ :son güncellemeden sonra adım sayısının çok hızlı büyüüp büyümediğini kontrol eder. Genelde $Mu/(1+Mu)$ olarak hesaplanır.), *öteleme* (ağırlık değerinin güncellenip güncellenmediğini denetler), *ağırlık yitimi* (ağırlıkların hızlı biçimde-birden büyümesini kontrol etmek için kullanılır) parametreleridir. Sınıflandırma uygulamasında kullanılan Quickpropagation ve geriyayılma algoritmasında kullanılan genel parametreler Tablo 4.8'de verilmektedir.

Tablo 4.8- Algoritmalarda kullanılan parametreler

Quickpropagation	Geriyayılma
başlangıç ağırlık değeri : 1	öğrenme oranı :0.01 - 0.2
başl.öğrenme oranı : 0.001	momentum :0.01-0.1
en büyük adım sayısı : 1.25	ağırlık yitimi :0.00001
öteleme : 0	
ağırlık yitimi : 0.00001	

Tabloda verilen parametre değerleri geneldir. Dolayısıyla problemin özelliğine göre bu parametreler genel parametrelere yakın olacak şekilde değiştirilmelidir. (Bu nedenle tabloda rakamlar arasında tireleme yapılmıştır.) Ayrıca quickpropagation algoritması ile çözüme 15 dakikada ulaşılmıştır. Lokal ağırlık bilgilerine bağlı olmaması ve optimum ağırlık setini daha 'çabuk' bulması nedeniyle geriyayılma algoritmasına tercih edilmesi gereken bir algoritmadır.

Olasıcı Sinir Ağlarının (Probabilistic Neural Networks) birçok sinir ağı modelinden (geriyayılma v.b.) daha çabuk öğrendiği ve hızlı çözüm sağladığı belirtilmişti. Aynı veri seti üzerinde yapılan sınıflandırma işlemi 20 dakika sürmüştü ve yüksek doğruluk (%93) sağlamıştır (Şekil 4.14). Bu yöntem kullanılarak sınıflandırma yapılacağı zaman gizli birimlerin (nöron) sayısını çok arttırmayacak sinir ağı yapılarının seçilmesine dikkat edilmelidir.

	Orman	yollar	Yerl. Alanı	deniz	boş alan	orman ²	yerl .alanı ²	Toplam
Orman	41946	0	72	0	0	165	1073	43256
yollar	0	29845	2643	0	0	148	623	33259
yerl. alanı	0	264	56194	0	0	736	2186	59380
deniz	387	0	475	26154	0	0	0	27016
boş alan	0	0	0	0	4546	0	118	4664
orman ²	0	324	0	0	0	27152	981	28457
yerl .alanı ²	86	0	8053	0	11	0	57962	66112
	Toplam Doğruluk : %93				Kappa katsayısı : 0.914			
Toplam	42419	30433	67437	26154	4557	28201	62943	262144
Üretici D.(%)	98,88	98,07	83,33	100	99,76	96,28	92,09	
Kullan. D.(%)	96,97	89,74	94,63	96,81	97,47	95,41	87,67	

Şekil 4.14 –Olasıcı sinir ağı sınıflandırması doğruluk değerlendirmesi (PIT yazılımı ile)

Uygulamada kullanılan sinir ağı türlerinin çözüme ulaşması için gereken iterasyon sayıları ile karesel ortalama hata değerleri Tablo 4.9'da görülmektedir. Tablodan görüleceği üzere optimum ağırlık setinin bulunabilmesi için geriyayılma algoritması kullanıldığında çok daha fazla iterasyon yapmak (ağı çalıştırmak) gerekmektedir.

Tablo 4.9 –Uygulamalarda kullanılan sinir ağlarının çözüm sonucu k.o.h. değerleri

Karesel Ortalama Hata Değerleri			
<i>İterasyon</i>	Quickpropagation	Geriyayılma	Olasıcı Sinir Ağı
10	0.00741	0.09381	0.00858
25	0.00548	0.00910	0.00846
50	0.00236	0.00864	0.00794
75	0.00102	0.00855	0.00667
100	0.00065	0.00839	0.00573
150	0.00034	0.00812	0.00466
..	...	...	...
1000	...	0.00452	...
2000	...	0.00278	...
3000	...	0.00196	...
10000	...	0.000416	...

Yapay sinir ağı ile sınıflandırma tekniği ile yakından ilişkili/ benzer algoritmaların (Bölüm 3.3) performansının incelenmesi ve elde edilecek bulguların diğer yöntemlerle karşılaştırılabilmesi amacıyla sözkonusu yöntemlerle de görüntü

sınıflandırması yapılmıştır. Uygulamada kullanılan tüm sınıflandırma yöntemleri için elde edilen sınıflandırma sonuçları Tablo 4.10' da görülmektedir.

Tablo 4.10- Sınıflandırma doğruluk değerlendirme sonuçları


Ençok benzerlik		Enküçük uzaklık		Fisher Disk. Anal.		MLP		ECHO		PNN		PDM	
Toplam Doğruluk	Kappa	Toplam Doğruluk	Kappa	Toplam Doğruluk	Kappa	Toplam Doğruluk	Kappa	Toplam Doğruluk	Kappa	Toplam Doğruluk	Kappa	Toplam Doğruluk	Kappa
89.5	0.87	87.6	0.86	89.1	0.87	94.4	0.93	88.4	0.87	93	0.91	87.6	0.85

Tabloda görüldüğü gibi, çok- tabakalı sinir ağı sınıflandırma doğruluğu standart parametrik sınıflandırma algoritmalarından (en çok benzerlik, enküçük uzaklık,...) daha yüksek bulunmuştur. Ancak bu sonuca ulaşmak için klasik yöntemlere oranla uzun zaman harcanmakta, (ağ tasarımı, parametrelerin seçimi, güven tahmini,...vb), kullanıcı deneyimi gerektirmekte ve bir bakıma optimizasyon problemine dönüşebilmektedir. Uygun sinir ağı mimarisi seçilmeden (rastgele tasarlanan) çalıştırılan bir sinir ağından yüksek doğruluk garantisi beklenmemelidir. Tez kapsamında önerilen doğruluk güven tahmin yöntemi, uygulaması kolay, çok fazla zaman gerektirmeyen ve sonuç sınıflandırma doğruluğu kalitesini arttırabilecek bir yaklaşımdır.

Uygulama sonuçlarına göre olası sinir ağı yaklaşımı, özellikle uygun ağ tasarımı yapılabilmesi halinde diğer sinir ağı modellerine kıyasla kısa sürede çözüme ulaşabilen, doğruluk değeri yüksek bir sınıflandırma yöntemi olmaktadır. ECHO konumsal- spektral sınıflandırma yöntemi ile Fisher'in diskriminant analiz yöntemi sınıflandırma doğrulukları, görüntü sınıflandırmasında (parametrik) rutin olarak kullanılmakta olan ençok benzerlik yöntemi doğruluğuna çok yakın bulunmuştur. Ayrıca Fisher diskriminant analiz yaklaşımının sinir ağına teorik benzerliği şaşırtıcıdır. Buradan sınıflandırma problemlerinde parametrik yaklaşımda, veri setinin olasılık dağılımının seçilecek sınıflandırma yöntemi için belirleyici olduğu vurgulanmalıdır. Veri setinin karakteristiklerini belirleme işleminin de kolay uygulanabilir olmadığını da teslim etmek gerekir. Bu noktada yapılacak bir 'ihmal'in sınıflandırma kalitesini etkileyeceği unutulmamalıdır. Enküçük uzaklık ile polinom diskriminant yöntemi sınıflandırma doğrulukları birbirine yakın ve diğer yöntemlere oranla düşük

bulunmuştur. (Uygulamalarda Multispec yazılımı kullanılarak yapılan görüntü sınıflandırması doğruluk değerlendirmesi örneği Tablo 4.11’de görülmektedir.)

Çok tabakalı sinir ağı toplam doğruluk grafiği çizildiğinde, belli bir çalışma (iterasyon) bölgesinden sonra sınıflandırma doğruluğunun yaklaşık olarak sabit kaldığı gözlenebilir (Şekil 4.15).



Şekil 4.15- Sinir ağı sınıflandırması toplam doğruluk grafiği

Şekilde görüleceği üzere 5000 iterasyon sayısından sonra sınıflandırma doğruluğu çizgisi yaklaşık yatay kalmakta ve uzun süre sonra doğruluk değeri az miktarda artmaktadır. Bu aralıkta, çalışma işleminde “aşırıyuma (overfitting, overtraining)” oluşup oluşmadığı önem kazanmaktadır. Bu durum genelleştirme kapasitesini (örnekleme bölgesi içinde yer almayan pikselleri doğru biçimde sınıflandırma yeteneği) etkileyebilecek bir durumdur. Bu kanıya varılmışsa ilk öğrenmenin olduğu bölgede ağı çalıştırılması durdurulmalı (bu değerle yetinilmeli), değilse en yüksek doğruluğun elde edildiği epokta ağı sonuçlandırılıp kabul edilmelidir. Uygulama örneğinde aşırıyuma probleminin oluşmadığı kanaatine varılarak, 12000.inci iterasyonda ağı çalıştırılması durdurulmuştur. Bu noktada elde edilen sınıflandırma doğruluğu optimum sonuç olarak değerlendirilmiştir.

Tablo 4.11- Sınıflandırmada doğruluk değerlendirmesi örneği

TRAINING CLASS PERFORMANCE (MultiSpec4.2.99) / List Results										
Project	Reference	Number of Samples in Thematic Image Class								
Class	Class	Accu.+	Number	1	2	3	4	5	6	7
Name	Number	(%)	Samples	orman	yollar	yerl.a.	deniz alan	boş	orman ²	yerl. alanı ²
orman	1	99.7	43256	42543	0	54	0	0	30	629
yollar	2	99.1	33259	0	31149	1716	0	0	76	318
yerl. alanı	3	85.3	59380	0	22	56824	0	0	431	2103
deniz	4	100.0	27016	77	0	86	26853	0	0	0
boş alan	5	99.8	4664	0	0	0	0	4596	0	68
orman ²	6	98.1	28457	0	253	0	0	0	27243	961
yerl. alanı ²	7	93.4	66112	35	0	7902	0	11	0	58164
TOTAL			262144	42655	31424	66582	26853	4607	27780	62243
Reliability Accuracy (%)*				98.3	93.6	95.7	99.4	98.5	95.7	87.9
OVERALL CLASS PERFORMANCE (247372 / 262144) = 94.4%										
Kappa Statistic (X100) = 93.1%. Kappa Variance = 0.000003.										
+ (100 - percent omission error); also called producer's accuracy.										
* (100 - percent comission error); also called user's accuracy.										

5. SONUÇLAR VE ÖNERİLER

Multispektral verilerin sınıflandırılmasında parametrik olmayan yapısı, olasılık dağılımı ile ilgili varsayımda bulunmaması, farklı veri türlerini kullanabilme yeteneği ve sınıflandırmaya yardımcı olabilecek ek bilgileri bütünleştirebilme özellikleri nedeniyle yapay sinir ağı teknolojisi yeni ve etkin bir araç olmuştur.

Görüntü sınıflandırması için kullanılan klasik yöntemler sınıflandırma işleminde olasılık dağılımı ile ilgili varsayım yapması ve örnekleme veri dağılımının özelliklerini dikkate almaması nedeniyle bazı sınırlamalar içermektedir. Pratik sınıflandırma uygulamalarında da veri dağılımının özelliklerine en çok uyan sınıflandırma algoritmasının seçilmesi de son derece önemlidir. Genel olarak non- parametrik algoritmaların parametrik algoritmalara nazaran daha yüksek doğruluk ürettiği bilinmektedir. Parametrik olmayan algoritmalar son zamanlarda "soft computing" olarak adlandırılan kavramla da özdeşleşmiştir. Benzer olarak görüntü sınıflandırmasında da 'esnek sınıflandırma algoritmaları' (soft classification techniques) olarak adlandırabileceğimiz yeni bir kavram kazandırılmıştır.

Parametrik olmayan yöntemlerden yapay sinir ağlarının görüntü sınıflandırmasında klasik yöntemlerden daha yüksek doğruluk ürettiği bilinmektedir. Ancak halihazırda yapay sinir ağları ile sınıflandırma işlemi klasik yöntemlere kıyasla uygulaması zor ve zaman alıcı bir işlemdir. Buna neden olarak ağ kurulumunun zaman alıcı olması, (parametre seçimi, çalıştırma koşulları,..vb.) ve kullanıcı deneyimi gerektirmesi gösterilebilir. Sonuçlar karşılaştırılırken bu unsurları da göz önünde bulundurmalıdır. Tez kapsamında sözkonusu algoritmaları karşılaştırmak için yeni bir yaklaşım geliştirilerek; multispektral (çokbandlı) uzayda sınıfları birbirinden ayıran yüzeylerin temel şekilleri (karar yüzeyleri) irdelenmiş ve yapay sinir ağlarının daha esnek (kapasiteli) karar sınırları oluşturduğu gösterilmiştir.

Sınıfların olasılık dağılımları hakkında belli varsayımlara göre kurulan algoritmaların yetersizliği göz önüne alınırsa; verilerin olasılık dağılımlarının gerçekçi biçimde tanımlanabilmesi için farklı yaklaşımlar geliştirilebilir. Bu amaçla farklı dağılım parametreleri ve istatistik testler kullanılmalıdır. Buna ek olarak tanımlanan dağılımın normal dağılım varsayımından farklı olup olmadığı istatistiksel olarak test edilebilir.

Buradan elde edilecek sonuçlarla sinir ağı sonuç değerleri karşılaştırılarak yorumlanabilir. (İyi genelleştirme yapabilen- uygun bir sinir ağı modelinin, veri dağılımını doğru biçimde temsil etmesi beklenir.) Bu nokta ileride yapılacak araştırmalar için iyi bir çıkış noktası olabilir.

Parametrik sınıflandırma yöntemlerinin yetersiz olduğu bir diğer husus, örnekleme veri seti büyüklükleri sınıflar arasında belirgin biçimde değiştiğinde, soncul olasılıkların doğru biçimde tahmin edilemiyor olmasıdır. Böyle bir durumun önceden kestirilmesi de zordur. Aynı problemin yapay sinir ağları ile yaşanmayacağı yönünde bir anlayış olmasına rağmen bu konu şimdiye değin ayrıntılı olarak ele alınmamıştır.

Yapay sinir ağları ile görüntü sınıflandırmasında genel olarak çok- tabakalı ileri- itilimli sinir ağları yaygın biçimde kullanılmaktadır. Uygulamalarda güvenilir ve pratik bir "güvenlik tahmin ölçüsü" tanımı çok gereklidir. Bu konuda yapılan araştırmalar incelendiğinde bu yöntemlerin değişik yaklaşımlara göre kurgulandıkları ve henüz genel bir çerçeve oluşturulmadığı gözlemlenebilmektedir. Tez çalışması kapsamında bu yöntemler iki başlık altında değerlendirilmiştir: Bir objenin tek olarak sınıflandırmasına dayanan yöntemler ve deneme veri setine bağlı olarak ağ sonuçlarının dağılımını modellendiren yöntemler. İkinci yöntemin daha gerçekçi ve uygulanmasının da daha kolay olduğu kanaatine varılmıştır. Bu noktadan hareketle sinir ağları doğruluklarının kestirilmesinde istatistik teorisine dayalı bir yaklaşım (ve yazılımı) geliştirilmiştir. Doğruluk kestiriminde güven aralıklarının kurulmasında "binom denemeler kuramından" yararlanan yeni bir algoritma oluşturulmuştur. Bu teknik yardımıyla, çalıştırılan bir sinir ağının önceden belirlenen bir hata sınırı içinde ve güven düzeyinde, ağın sonuç değerlerini kullanarak istatistiksel anlamda ağın kabul edilebilirliği üzerinde bir test ölçütü oluşturulmaktadır. Uygulamalarda yöntemin kullanılabilirliği gösterilmiştir. Oluşturulan yöntemin bir diğer yararı, yapay sinir ağı uzmanlarının üzerinde en çok çalıştığı konuların başında gelen "uygun ağ mimarisinin seçimi" konusunda kullanılabilir oluşudur. Sinir ağlarının farklı başlangıç koşullarıyla ve çok sayıda gerçekleştirilen simülasyon sonuçları sözkonusu teknikle değerlendirilebilir.

Uygun ağ yapısının belirlenmesi için yapılan araştırmalarda ağ büyüklüğünün (nöron sayısı, gizli tabakalar, birimler arasındaki ilişkiler, tabaka sayısı,..vb.) son derece önemli olduğu vurgulanmış; ağın kapasitesi, öğrenme zamanı ve genelleştirme yeteneğinin buna bağlı olduğu belirtilmiştir. Büyük boyutlu ağların çalıştırılması daha çok zaman almakta ve daha fazla örnekleme verisine gereksinim duymaktadır. Küçük boyutlu ağlar ise kolaylıkla yerel minimum değerine yakınsayarak iyi

genelleştirme yapamamaktadır. Bu nedenle hiyerarşik bir yaklaşım kullanılarak (küçük boyutlu bir ağla başlayıp nöron ve tabaka sayıları ardışık olarak artırılarak büyük boyutlara ulaşmakta veya tersi) uygun ağ modeli seçilmeye çalışılmaktadır. Bunun yerine önerilen güven tahmin yöntemi kullanılırsa çok sayıda deneme yapmaktan kaçınılmış olacaktır.

Yapay sinir ağları uygulamalarında en çok kullanılan algoritma geriyayılma olup kullanım kolaylığı nedeniyle yaygın biçimde tercih edilmektedir. Tez kapsamında ise bu yöntemin sakıncalarına değinilmiş (yavaş olması, yerel minimuma yakalanma riski, ..vb.) ve bu yöntem yerine daha gelişmiş yöntemlerin (quickprop vb.) kullanımı önerilmiştir. Ayrıca tez içinde önerilen yöntemle (ve HYSYA yazılımı); non- lineer optimizasyonu gerçekleştirmek için geriyayılmadan daha üstün bir yöntem olan Levenberg- Marquardt yöntemine dayanan bir algoritma (yeni bir varyasyon) geliştirilmiştir. Uygulamalarda hızlı oluşu, global minimuma yakınsama (çözüm) garantisi, sayısal kesinliğe sahip oluşu ve az sayıda kullanıcı- tanımlı parametre gerektirmesi nedeniyle daha üstün bir yöntem olduğu ileri sürülebilir.

Yapay sinir ağlarında uygun ağ yapısı seçiminin önemi belirtilmişti. Bu noktada tartışılması gereken bir diğer konu "probleme özgün" ağ yapılarının nasıl seçilebileceği olmalıdır. Sözgelimi görüntü sınıflandırmasında MLP sinir ağının tercih ediliyor olmasının nedenini; bu tür ağların sınıfların soncul olasılıklarını doğru biçimde tahmin edebilmesiyle açıklayabiliriz. Çok fazla sayıda türü (ve varyasyonları) olan yapay sinir ağlarının bu anlamıyla da analiz edilmesi ve özelliklerinin ortaya konulmasında son derece yarar vardır. Çözülecek problemin yapısına uygun sinir ağı tipini seçmek ve kurallarını oluşturmak gerekmektedir.

Yapay sinir ağlarının bazı türlerinin istatistik analiz algoritmalarıyla benzeştiği, hatta kimi zaman örtüştüğü öne sürülmektedir. Bunun sınıflandırma ile ilgili belki de en güzel örneği, sinir ağı sonuç değerlerinin aynı zamanda Bayes soncul sınıf olasılıkları olarak değerlendirilebilmesidir. İleri-ittimli (feedforward) sinir ağları da aslında bir tür non-lineer regresyon modelidir. Tez çalışmasında incelenen Fischer diskriminant analizin teorik yaklaşımı ile sinir ağı benzerliği ilginç bulunmuştur. Bu tür sonuçların irdelenmesi, sinir ağı sonuçlarının yorumlanması açısından son derece ilginç olabilir.

Günümüzde sınıflandırma işlemleri için kullanılan verilerin miktarı, türü ve duyarlılığı hızla artmakta buna paralel olarak da daha sofistike algoritmaları kullanma gereksinimi doğmaktadır. Klasik algoritmaların bu anlamda yetersiz kaldığı bilinen

bir gerçektir. Bu noktada yapay sinir ağıları, farklı veri türlerini kullanabilme ve entegrasyon yapabilme özelliği nedeniyle üstündür.

Uygulama sonuçları yapay sinir ağıları ile daha yüksek sınıflandırma doğruluğuna (klasik parametrik yöntemlere göre) ulaşılabilirliğini göstermiştir. Buna karşın halihazırda sinir ağıları ile sınıflandırma işlemi, standart yöntemlere oranla hem zaman alıcı hem de daha çok uğraş (deneyim) gerektiren bir araç durumundadır. Yakın bir gelecekte sinir ağlarının kullanımı kolay ve standart bir araç olacağını tahmin etmek zor değildir. (PIT yazılımı içinde yer alan sinir ağı modeli bunun güzel bir örneğidir.) Bilgisayar donanım ve yazılım teknolojisindeki hızlı gelişmeler dikkate alındığında, yapay sinir ağıları; yakın zamanda görüntü sınıflandırması için diğer standart yöntemlere alternatif olarak uygulaması kolay ve güçlü bir teknik olacaktır. Ayrıca görüntü sınıflandırması ile birlikte, sayısal görüntü işleme teknolojisinin diğer dallarında da kullanım alanı bulabileceğini öngörmek zor değildir.

Sonuç olarak yapay sinir ağıları, görüntü sınıflandırmasına yeni kuramsal ve pratik açılımlar getiren, gelişmiş, duyarlı ve yetkin bir teknoloji olarak değerlendirilmelidir.

KAYNAKLAR

- Alder, H. L., 1972. Introduction to Probability and Statistics. Fifth Edition. University of California, USA.
- Atkinson, P. M., and Tatnall, A. R. L., 1997. Neural networks in remote sensing, *International Journal of Remote Sensing*, **18**, 699- 709.
- Bartlett, P.L., 1997. For valid generalisation, the size of the weights is more important than the size of the network, *Advances in Neural Information Processing Systems*, **9**, 134-140.
- Bebis, G., and Georgiopoulos, M., 1999. Feedforward neural networks : why network size is so important, *IEEE Potentials*, November 1999, 27- 31.
- Benediktsson, 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.
- Benediktsson, 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*, **28**, 540-552.
- Bernard, A. C., Wilkinson, G. G., and Kanellopoulos, I., 1997. Training strategies for neural network soft classification of remotely- sensed imagery, *International Journal of Remote Sensing*, **18**, 1851- 1856.
- Binaghi, E., Brivio, P. A., and Rampini, A., 1996. Soft computing in remote sensing data analysis, *World Scientific*, **19**, 217-240.
- Bischof, H., Schneider W., and Pinz, A. J., 1992. Multispectral classification of Landsat-images using neural networks, *IEEE Transactions on Geoscience and Remote Sensing*, **30**, 482-490.

- Bishop, C.M. , 1995. *Neural Networks for Pattern Recognition*. Oxford University Press.
- Bosch, E.H., 1994. The effects different neural network architectures have on the exploitation of hyperspectral data, *Imagery Research Division Technical Report*, U.S. Army Topographic Engineering Center.
- Caruana, R., Lawrence, S., and Giles, L., 2000. Overfitting in neural nets: Backpropagation, conjugate gradient, and early stopping, *The Conference on Neural Information Processing Systems*, Colorado, November 2000, 28- 30.
- Chen, K.S., Tzeng, Y.C., Chen, C.F. and Kao, W.L., 1995. Land-cover classification of multispectral imagery using a dynamic learning neural network, *Photogrammetric Engineering and Remote Sensing*, **61**, 403-408.
- Congalton, R. G., and Story, M., 1986. Accuracy assessment- A user's perspective, *Photogrammetric Engineering and Remote Sensing*, **52**, 397- 399.
- Dietterich, T. G., 1998. Approximate statistical tests for comparing supervised classification learning algorithms, *Neural Computation*, **10**, 1895- 1923.
- Dreyer, P., 1993. Classification of land cover using optimized neural nets on SPOT data, *Photogrammetric Engineering and Remote Sensing*, **59**, 617- 621.
- Duin, R. P. W., 1993. Nearest neighbor interpolation for error estimation and classifier optimization, *Proceedings of the 8th SCIA Conference*, July 1993, Netherlands.
- Edwards, P. J., Papadopoulos, G., and Murray, A. F., 2000. Confidence estimation methods for neural networks: A practical comparison, Internal report in Department of Electronics and Electrical Engineering, University of Edinburgh.
- Efron, B., and Tibshirani, R., 1993. *An Introduction to the Bootstrap*. Chapman & Hall. Chicago.
- Fierens, F., Kanellopoulos, I., Wilkinson, G.G. and J. Mégier, 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, 1880-1882, IEEE Press.

- Fine, T. L., 1999. Feedforward Neural Network Methodology. Springer-Verlag. New York.
- Flexer, A., 1995. Statistical evaluation of neural- network experiments: Minimum requirements and current practice, *Austrian Res. Inst. Artificial Intelligence Technical Report*, OEFAI- TR- 95-16, Vienna, Austria.
- Foody, G. M., 1995. Land cover classification by an artificial neural network with ancillary information, *International Journal of Geographical Information Systems*, **9**, 527-542.
- Freund, J. E. ve Walpole, R. E., 1987. Mathematical Statistics. Prentice Hall. New Jersey.
- Gualtieri, J.A. and Withers, J., 1988. Goddard researchers simulate neural networks using parallel processing, *NASA Information Systems Newsletter*, **15**, 12-15.
- Hassibi, B., and Stork, D. G., 1993. Second- order derivatives for network pruning: Optimal Brain Surgeon. In *Advances in Neural Information Processing Systems* , **5**, 164-171, Eds. Hanson, S. J., Cowan, J. D. and Giles, C. L.
- Haykin, S., 1999. Neural Networks : A Comprehensive Foundation. Second edition. Prentice Hall. Upper Saddle River.
- Hepner, G.F., Logan, T., Ritter, N. and Bryant, N., 1990. Artificial neural network classification using a minimal training set: Comparison to conventional supervised classification, *Photogrammetric Engineering and Remote Sensing*, **56**, 469-473.
- Heskes, T., 1997. Practical confidence and prediction intervals, in *Advances in Neural Information Processing Systems*, **9**, 176- 182. The MIT Press.
- Hoekstra, A., Tholen, S. A., and Duin, P. W., 1996. Estimating the reliability of neural network classifications, *Proceedings of the ICANN'96*, December 1996, 53- 58.
- Howald, K.J., 1989. Neural network image classification, *Proceedings ASPRS-ACSM Fall Convention*, "From Compass to Computer", Cleveland, 207-215.
- Jensen, J. R., 1996. Introductory Digital Image Processing – A Remote Sensing Perspective. Second Edition. Prentice Hall Series in Geographic Information Science, USA.

- Kamgar-Parsi, B., Gualtieri, J.A., Devaney, J.E. and Kamgar-Parsi, B., 1990. Clustering with neural networks, *Biological Cybernetics*, **63**, 201-208.
- Kanellopoulos, I., Varfis, A., Wilkinson, G.G. and Mégier, J., 1992. Land cover discrimination in SPOT HRV imagery using an artificial neural network-a 20-class experiment, *International Journal of Remote Sensing*, **13**, 917-924.
- Kanellopoulos, I., Varfis, A., Wilkinson, G.G. and Mégier, J., 1991. Neural network classification of multi-date satellite imagery, *Proceedings of the International Geoscience and Remote Sensing Symposium (IGARSS'91)*, Espoo, Finland, 2215-2218, IEEE Press.
- Kavzoglu, T., and Mather, P. M., 1998. Assessing artificial neural network pruning algorithms, *Proceedings of the 24th Annual Conference and Exhibition of the Remote Sensing Society*, 603- 609, Greenwich, UK.
- Kearns, M., Yishay, M., Andrew, N., and Dana, R., 1997. An experimental and theoretical comparison of model selection methods, *Machine Learning*, **27**, 7- 50.
- Key, J., Maslanic, A. and Schweiger, A.J., 1989. Classification of merged AVHRR and SMMR arctic data with neural network, *Photogrammetric Engineering and Remote Sensing*, **55**, 1331-1338.
- Kohavi, R., 1995. A study of cross- validation and bootstrap for accuracy estimation and model selection, *Proceedings of the International Joint Conference on Artificial Intelligence (IJCAI)*, 1137- 1143.
- Lawrence, S., Back, A. D., Tsoi, A. C., and Giles C. L., 1997. On the distribution of performance from multiple neural- network trials, *IEEE Transactions on Neural Networks*, **8**, 156-172, November 1997.
- Lawrence, S., Burns, I., Back, A., 1998. Neural network classification and prior class probabilities, *Lecture Notes in Computer Science State-of-the-Art Surveys*, Eds. Orr, G., Müller, K. R. and Caruana, R., 299-314. Springer Verlag.

- Lawrence, S., Giles, C. L., and Tsoi, A.C., 1997. Overfitting may be harder than expected, *Proceedings of the Fourteenth National Conference on Artificial Intelligence*, AAAI-97, California, USA, 540- 545.
- Le Cun, Y., Denker, J. S., and Solla, S. A., 1990. Optimal Brain Damage. *Advances in Neural Information Processing Systems* , 2, 598- 605, edited by Touretsky, D.S.
- Lee, J., Weger, R.C., Sengupta, S.K. and Welch, R.M., 1990. A neural network approach to cloud classification, *IEEE Transactions on Geoscience and Remote Sensing*, 28, 846-855.
- Lin, S.H., Kung,S.Y. and Lin L.J., 1997. Face recognition/ detection by probabilistic decision-based neural network, *IEEE Trans. On Neural Networks*, Special Issue on Biometric Identification, 114- 132.
- Lippman, Richard P., 1987. An introduction to computing with neural nets, *IEEE Trans. ASSP Magazine* ,4, 4-22.
- Mak, M.W., Li, C.K., and Li, X., 1998. Maximum likelihood estimation of elliptical basis function parameters with application to speaker verification, *Proceedings of the International Conference On Signal Processing*, Florida,1287-1290.
- Martinez, T. R., and Wilson, D. R., 1997. Improved center point selection for probabilistic neural networks, *Proceedings of the International Conference on Artificial Neural Networks and Genetic Algorithms*, (ICANNGA'97), Ontario, 514- 517.
- Masters, T., 1995. Advanced Algorithms for Neural Networks. John Wiley and Sons. England.
- Mather, P. M., and Kavzoglu, T., 2000. Using feature selection techniques to produce smaller neural networks with better generalisation capabilities, *Proceedings of the IGARSS' 2000*, Hawaii, USA, 247-258.
- Mather, P.M., 1989. Computer Processing of Remotely Sensed Images: An Introduction. University of Nottingham. John Wiley and Sons. England.
- Norgaard, M., Jorgensen, C.C., and Ross, J. C., 1997. Neural network prediction of new aircraft design coefficients, *NASA Technical Memorandum*, 112197, Ames Research Center, California.

- Örmeci, C., 1995. Quantitative Remote Sensing, Yüksek Lisans Programı Ders Notları-Seminerler (basılmamış), İ.T.Ü. Fen Bilimleri Enstitüsü.
- Paola J.D. and Schowengerdt, R.A., 1994. Comparison of neural networks to standard techniques for image classification and correlation, *Proceedings of the International Geoscience and Remote Sensing Symposium (IGARSS'94)*, Pasadena, California, 1404-1406.
- Paola, J. D. and Schowengerdt, R.A., 1995. A review and analysis of backpropagation neural networks for classification of remotely sensed multi-spectral imagery, *International Journal of Remote Sensing*, **16**, 3033-3058.
- 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 Geoscience and Remote Sensing*, **33**, 981-996.
- Prechelt, L., 1998. Automatic early stopping using cross validation : quantifying the criteria. *Neural Networks*, **11**, 761- 767.
- Richards, J. A. and Jia. X., 1995. Remote Sensing Digital Image Analysis. The University of New South Wales. Campbell, ACT, Australi.
- Schowengerdt, R.A., 1983. Techniques for Image Processing and Classification in Remote Sensing. University of Arizona. Academic Press. Tucson.
- Schölkopf, B., Mika, S., Burges, C., Knirsch, P., Müller, K. R., and Smola, A., 1999. Input space vs. feature space in kernel- based methods, *IEEE Transactions on Neural Networks*, Special Issue on VC Learning Theory and Its Applications, 58-75, Pittsburgh, USA.
- Shashua, A., 1999. On the relationship between the support vector machine for classification and sparsified Fisher's Linear Discriminant, *Neural Processing Letters*, **9**, 129-139, April 1999.
- Smola, A., Müller, K. R., and Schölkopf, B., 1998. Nonlinear component analysis as a kernel eigenvalue problem. *Neural Computation*, **10**, 1299-1319.

- Solaiman, B. and Mouchet M.C.**, 1996. A comparative study of conventional and neural network classification of multispectral data, *Ecole Nationale Supérieure des Télécommunications de Brotagne*, Cedex, FRANCE.
- Specht, D. F.**, 1992. Enhancements to probabilistic neural networks. *Proceedings of the International Joint Conference on Neural Networks (IJCNN' 92)*, Seattle, USA, February 1992, 761- 768.
- Stehman, S. V.**, 1996. Estimating the Kappa coefficient and its variance under stratified random sampling, *Photogrammetric Engineering and Remote Sensing*, **62**, 401- 407.
- Stepniewski, S. W., and Jorgensen C. C.**, 1998. Toward a more robust pruning procedure for MLP networks, *NASA Technical Report*, **TM- 1998- 112225**, April 1998, USA.
- Tholen, S. A.**, 1995. Confidence values for neural network classifications. Pattern Recognition Group technical report, Delft University of Technology, Netherlands.
- Tibshirani, R.**, 1996. A comparison of some error estimates for neural network models, *Neural Computation*, **8**, 152- 163.
- Vieira, C. A. O.**, 1998. Using multitemporal, multispectral and multisource remotely sensed data to classify crops: An innovative approximation, *Proceedings of the Remote Sensing Society Conference*, Oxford, 47-52.
- Weiss, S. M.**, 1991. Small sample error rate estimation for k- nearest neighbor classifiers, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **13**, 285- 289.
- Wilkinson, G.G., Fierens, F., and Kanellopoulos, I.**, 1995. Integration of neural and statistical approaches in spatial data classification, *Geographical Systems*, **2**, 1-20.
- 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, *Proceedings of the International Symposium on Dimethylsulphide, Oceans, Atmosphere and Climate*, Commission of the European Communities, Joint Research Centre, Belgirate, Italy.
- Wilson, D. R., and Martinez, T. R.**, 2000. The inefficiency of batch training for large training sets, *IEEE Transactions on Neural Networks*, **6**, 126- 143.

Wilson, R. D. and Martinez, T. R., 2000. The robustness of relaxation rates in constraint satisfaction networks. Lecture notes in Computer Science Department, Brigham Young University.

Wolpert, D., 1997. On bias plus variance, *Neural Computation*, **9**, 1211- 1243.

Yaeger, L., Lyon, R., and Webb, B., 1997. Effective training of a neural network character classifier for word recognition, *Advances in Neural Information Processing Systems*, **9**, Cambridge, MA, MIT Press.

Yiu, K.K., Mak, M.W., and Li, C.K., 1999. Gaussian mixture models and probabilistic decision-based neural networks for pattern classification, Internal report in Department of Electronic and Information Engineering, Polytechnic University, Hong Kong.

Zeng, X., and Martinez, T. R., 1999. Extending the power and capacity of constraint satisfaction networks, *Proceedings of the IEEE International Joint Conference on Neural Networks (IJCNN'99)*, Virginia, USA.


Sinir Ağı Sınıflandırmasında Kullanılacak Görüntü Alt-alanı (Training set)

92


Ham Görüntü

Ek A.1- Uygulamalar İçin Seçilen Görüntü Ve Altalan Örneği


EK A.2- Multispec Görüntü Sınıflandırma Yazılımı Menüsü




EK A.3- PIT Görüntü İşleme Yazılımı Menüsü




EK A.4- ThinksPro Sinir Ağı Yazılımı Menüsü



EK B.1- Örnekleme Bölgelerinin Görünümü (PIT Yazılımı)





Sinir Ağı Yazılımı Giriş Menüsü

The screenshot displays the 'Neural Network Setup' dialog box. The 'Architecture' is set to 'Multilayer Normal Feed Forward'. The 'Error Type' is 'Mean Square Error'. The 'Hidden Layers' is set to 1, and the 'Random Seed' is 467. The 'Batch Size' is set to 1. The 'Training Set' is selected. The 'Layer Definition' section shows 'Nodes' as 2 and 'Max Nodes' as 3. The 'Learning Rule' is 'Quick Propagation (QP)'. The 'Input Function' is 'Dot Product' and the 'Transfer Function' is 'Threshold Linear'. The 'Hidden Layer 1 QP Parameters' section shows 'Initial weights value (InitWtsVal)' as 1, 'Shrink factor (Delta)' as 0.4444, 'Initial learning rate (Epsilon)' as 0.001, 'Max step size (Mu)' as 1.25, 'Transfer offset (Offset)' as 0, and 'Weights decay (WtsDecay)' as 1e-005.

Sinir Ağı Kurulum Menüsü

ThinksPro - TEZT51.NET

File Edit Options Run View Window Help

Iteration

Test Set

	I1	I2	I3	O1	O2	O3	O4	O5	O6
124904	133	136	134	0.332073	0.775313	0.613541	0.899532	0.463869	0.3064
124905	110	147	106	0.332073	0.775313	0.613541	0.899532	0.463869	0.3064
124906	121	143	115	0.332073	0.775313	0.613541	0.899532	0.463869	0.3064
124907	125	129	129	0.332073	0.775313	0.613541	0.899532	0.463869	0.3064
124908	110	129	106	0.332073	0.775313	0.613541	0.899532	0.463869	0.3064
124909	96	132	88	0.687876	0.84486	0.611673	0.886325	0.691928	0.4940
124910	92	160	69	0.206131	0.800875	0.474253	0.352592	0.617913	0.8227
124911	110	160	92	0.687876	0.84486	0.611673	0.886325	0.691928	0.4940
124912	96	129	88	0.632262	0.834625	0.611902	0.888828	0.957032	0.4611
124913	110	122	83	0.332073	0.775313	0.613541	0.899532	0.463869	0.3064
124914	133	118	120	0.332073	0.775313	0.613541	0.899532	0.463869	0.3064
124915	173	114	180	0.332073	0.775313	0.613541	0.899532	0.463869	0.3064
124916	203	132	203	0.332073	0.775313	0.613541	0.899532	0.463869	0.3064
124917	232	158	241	0.332073	0.775313	0.613541	0.899532	0.463869	0.3064
124918	140	118	120	0.332073	0.775313	0.613541	0.899532	0.463869	0.3064

NUM: 12:16

Veri Setini Test Etme Opsiyonu

ThinksPro - TEZT51.NET

File Edit Options Run View Window Help

Run Options

Learning C OFF

Learning C ON

Testing Options

- ☐ Use Test Set as input
- ☒ Use Training Set as input
- ☐ Input Sensitivity Analysis
- ☐ Confusion Matrix Analysis

Training Options


- ☐ Evaluate Test Set while training
- Stop when Training Set error is less than: 1.e-002
- Maximum iterations: Current iteration: 51
- ☐ Infinite
- ☒ 1000
- Reset
- Training sample presentation sequence:
 - ☒ Normal
 - ☐ Shuffle (random sequence through set)
 - ☐ Random (random selection of samples)
- Random seed: 55555
- ☐ Temporal Difference (reversed)

Test Set

NUM: 22:17

Sınır Ağı Çalıştırma Seçenekleri

EK B.4- Sinir Ağının Çalıştırma Esnasındaki Durumu ve Sonuçların Gösterimi



11	12	13	o1	o2	o3	o4	o5	o6	o7	d1	
22	140	23	1.000000000000107	0	0	0	0	0	0	1	0
7	107	9	.9999999999998621	0	0	0	0	0	0	1	0
25	150	18	.99999999999978856	0	0	0	0	0	0	1	0
7	114	9	.999999999999591	0	0	0	0	0	0	1	0
7	111	13	.9999999999995739	0	0	0	0	0	0	1	0
29	172	32	.9999999999994181	0	0	0	0	0	0	1	0
29	132	27	1.000000000000304	0	0	0	0	0	0	1	0
7			.9999999999995739	0	0	0	0	0	0	1	0
11	118	13	1.000000000000011	0	0	0	0	0	0	1	0
33	140	27	1.000000000000049	0	0	0	0	0	0	1	0
18	111	13	.9999999999996165	0	0	0	0	0	0	1	0
7	107	13	1.000000000000069	0	0	0	0	0	0	1	0
7	116	9	.9999999999993956	0	0	0	0	0	0	1	0
7	107	9	.999999999999972	0	0	0	0	0	0	1	0
7	104	9	.9999999999998621	0	0	0	0	0	0	1	0
22	125	23	.9999999999997914	0	0	0	0	0	0	1	0
14	114	13	1.0000000000000283	0	0	0	0	0	0	1	0
11	118	9	1.000000000000098	0	0	0	0	0	0	1	0
11	129	13	.999999999999902	0	0	0	0	0	0	1	0
7	122	9	.999999999999949	0	0	0	0	0	0	1	0
7	104	9	.999999999999539	0	0	0	0	0	0	1	0
3	96	9	.9999999999997914	0	0	0	0	0	0	1	0
7	104	9	.9999999999998791	0	0	0	0	0	0	1	0
7	104	9	.9999999999997914	0	0	0	0	0	0	1	0

EK B.5

TİCARİ OLMAYAN YAPAY SİNİR AĞI YAZILIMLARI

Yazılım Adı	Kullanılan Algoritma	Platform	Geliştiren	Erişim Adresi
The ART Gallery	ART1, ART2, Fuzzy ARTmap, ARTmap	Windows, UNIX	Lars H. Liden	Dept. Of Cognitive and Neural Systems, Boston University
Aspirin/Migraines	Geriyayılma (BP)	UNIX	Russel R. Leighton	Mitre Corporation, USA
BackBrain	Geriyayılma	Macintosh		University of Southampton, Highfield, SO17 1BJ, UK
Backprop-1.4	Geriyayılma	DOS		University of Kassel, Germany
Basis of AI	BP, QuickPropagation, Recurrent BP, LVQ	UNIX, DOS, and Windows	Don Tvetter	
bps	Geriyayılma	PC, VAX, Mac	Prof. Eugene Norris	George Mason University, Computer Science Dept., Virginia, USA
Con-x	Geriyayılma	Win95, DOS, Linux		University of Arkansas, Department of Computer Science
Fuzzy ARTmap	FuzzyARTmap		Boston University	Dept. Of Cognitive and Neural Systems
LVQ PAK	Learning Vector Quantizer		T.Kohonen, J. Hynninen	Helsinki University of Technology, Laboratory of Computer and Information Science, Finland
Matrix Backpropagation	Geriyayılma		University of Genoa	University of Genoa, Italy
MUME	feedforward, simple recurrent	Sun and DEC	Marwan Jabri	Sydney University, Sydney, NSW 2006, Australia
NETS	Geriyayılma	IBM, Macintosh, VAX, Sun	COSMIC	The University of Georgia, USA
NeuDL	Geriyayılma		Joey Rogers	The University of Alabama
NevProp	Feedforward BP, QuickPropagation	DOS, Macintosh, Unix	University of Nevada	University of Nevada, USA
NNMODEL	Geriyayılma	Windows 95/NT	Neural Fusion	Middletown, New York 10940, USA
NNSYSID	Feedforward	MATLAB 4.2/ 5	Magnus Nørgaard	Department of Automation, Technical University of Denmark
Pittnet	Feedforward, ART1, Kohonen SOM, RBF	DOS	B. Camahan and A. Smith	University of Pittsburgh, PA 15261, USA
QwikNet	BP, Quickprop, and Recurrent	Windows 3.1 /NT	Craig Jensen	
SOM PAK	Self-Organizing Map		Teuvo Kohonen	Helsinki University of Technology, Finland
SOM Toolbox for Matlab	Self-Organizing Map		T. Kohonen, Juha Vesanto	Helsinki University of Technology, Finland
Stuttgart Neural Network Simulator	ART, BP, LVQ QuickBP, SOM	SunOS, Ultrix, Unix	University of Stuttgart	Breitwiesenstr. 20/22, 70565 Stuttgart, Germany
WinNN	Geriyayılma, feedforward	MS-Windows		Washington University at Saint Louis
Xerion Simulator	Geriyayılma, LVQ, SOM, recurrent	Silicon Graphics and Sun	Xerion Project	Dept. Of Computer Science, University of Toronto, Ontario, Canada

NOT: Kısaltmalar : BP:Backpropagation, ART: Adaptive Resonance Theory, SOM: Self-Organising Maps, LVQ: Learning Vector Quantization, RBF: Radial Basis Functions, MLP: Multilayer Perceptron

Yazılım Adı	Kullanılan Algoritma	Platform	Geliştiren Firma	Erişim Adresi
Adaptive Logic Network	Adaptive Logic Networks	MS-Windows	Dendronic Decisions Limited	Jasper Avenue, Edmonton, Alberta T5J 3R8, Canada
Braincel		MS-Windows	Promised Land Technologies	195 Church Street, 11th Floor, New Haven, CT 06516, USA
BrainMaker	Geri yayılma	Windows 95, /NT, DOS, Macintosh	California Scientific Software Co.	10024 Newtown Rd., Nevada City, CA, 95959 USA
BrainSheet for Win95	Geri yayılma	Windows 95	BitStar International	239 Bellevue Avenue, Seattle, WA 98102, United States
Clementine	MLP, RBF, SOM, K-means	Windows NT, UNIX	SPSS Inc.	233 S. Wacker Dr., Chicago, IL 60606-6307, United States
DataEngine	fuzzy logic, neural networks	Windows 3.1, 95, NT	Management of Intelligent Technologies	Promenade 9, 52076 Aachen, Germany
Domain Solutions	BP, ART, SOM, Hopfield, Adaline	Windows, Unix	Domain Solutions, Inc.	P.O. Box 2722, Corpus Christi, Texas 78403-2722, USA
ECANSE	Hybrid System	UNIX, Win NT	Siemens Austria	Gudrunstrasse 11, A-1100 Vienna, Austria
FlexTools	Neural Networks, Fuzzy Logic	Windows and MatLab	Flexible Intelligence Group, LLC	Box 1477, Tuscaloosa, AL 35486, USA
havBpNet++	Geri yayılma	DOS, Win, NT, UNIX, HP, SUN	hav.Software	P.O. Box 354, Richmond, TX 77406-0354, USA
MacBrain	Hopfield, Hebbian, Geri yayılma	Macintosh	Neurix	327 A Street, Sixth Floor, Boston, MA 02210
Matlab: Neural Network Toolbox	Levenberg-Marquard, BP, SOM, Hopfield	Windows, MacOS, UNIX	The MathWorks	24 Prime Park Way, Natick, Massachusetts, 01760, USA
Neural Connection	MLP, RBF, SOM, Bayesian Neural N	Windows 3.1/ 95/98	SPSS Inc.	233 S. Wacker Dr., Chicago, IL 60606-6307, United States
Neural Network Utility/2	BP, ART1, SOM	OS/2, OS400, MS-Windows	IBM Corporation	1501 California Ave., P.O. Box 10500, Palo Alto, CA 94303, USA
NeuralWorks	BP, Probabilistic Nets, SOM, LVQ	PC, Macintosh, Sun, SGI, Dec	NeuralWare Inc.	202 Park West Drive, Pittsburgh, PA 15275, USA
Neuframe	Neuro-fuzzy	Windows 95/ NT	NCS	Nutwood Way, Totton, Southampton, SO40 3WW, UK
NeuroClassifier	self-organizing nets	MS-Windows	ATTG	P.O. Box 24104, 601 Dundas St. West, Whitby, ON, Canada
NeuroCoM	BP, Quickprop, Statistical	Windows 3.1, 95, NT	TransferTech GmbH	Cyriaksring 9A, 38118 Braunschweig, Germany
NeuroLab	Hopfield, recurrent Perceptron, MLP	Macintosh, MS-Windows	Mikuni Berkeley R & D Corp.	4000 Lakeside Dr., Richmond, CA 94806-1936, USA
NeuroModel®	Geri yayılma	WIN NT, WIN 95, UNIX, VMS	ATLAN-tec KG	Hanns-Martin-Schleyer-Str. 18 A; D-47877 Willich, Germany
NeuroShell	BP, SOM, Probabilistic Nets	MS-Windows	Ward Systems Group, Inc.	Executive Park West, 5 Hillcrest Drive, Maryland 21702, USA
NeuroSolutions	Çok kapsamlı, NN simülasyonu	Windows 95 and NT	NeuroDimension Incorporated	1800 N. Main St., Suite D4, Gainesville, FL 32609, USA
NeuroWindows	BP, PNN, Recurrent Kohonen Nets	MS-Windows	Ward Systems Group, Inc.	Executive Park West, 5 Hillcrest Drive, Maryland 21702, USA

Partek	neural net, fuzzy, genetic	UNIX, Windows	Partek Incorporated	1266-E Jungermann Rd., St. Peters, MO 63376, USA
Pattern Recognition Workbench	BP,RBF,k-means, Gauss.Mixt.Model	Windows	Unica Technologies Inc.	55 Old Bedford Road, Lincoln, MA 01773-1125, USA
PREVIA	BP, HAM, BSB, LVQ	MS-Windows	Elseware S.A.	38, rue de Ponthieu, 75 008 Paris, France
STATISTICA: Neural Networks	Geniş kapsamlı (Lev.Marq,PNN.....	Windows 95, NT	StatSoft, Inc.	2300 E. 14th St., Tulsa, OK 74104, United States
Trajan	Geniş kapsamlı	PC and UNIX	Dr. Andrew Hunter, Trajan Software LTD	Trajan House, Chester-le-Street, Co. Durham, DH2 3SR, UK
WinBrain	Geriyaılma	MS-Windows	Applied Cognetics Inc.	65 High Ridge Road, Suite #163, Stamford, CT 06905, USA

ÖZGEÇMİŞ

1968 yılında Anamur' da doğdu. 1990 yılında İ.T.Ü. İnşaat Fakültesi Jeodezi ve Fotogrametri Mühendisliği Bölümü' nden mezun oldu. 1991 yılında aynı bölümün Fotogrametri Anabilim Dalı' na Araştırma Görevlisi olarak atandı ve yüksek lisans öğrenimine başladı. Yüksel lisans tezini "Coğrafi Bilgi Sistemleri" konusunda hazırladı ve 1993 yılında yüksek lisans öğrenimini tamamladı. Aynı yıl üniversitedeki görevinden ayrılarak burs almış olduğu D.S.İ. Genel Müdürlüğü' nde çalışmaya başladı. Yüksek lisans öğrenimini tamamladıktan sonra İ.T.Ü. Uzaktan Algılama Anabilim Dalı' nda doktora öğrenimine başladı.

Halen D.S.İ. Genel Müdürlüğü Emlak ve Kamulaştırma Daire Başkanlığı' nda çalışmaktadır. Coğrafi Bilgi Sistemleri (GIS), Uzaktan Algılama, Uydu Bazlı Konum Belirleme Sistemi (GPS: Global Positioning System) ve sayısal harita üretimi ile ilgili konularda çalışmalar yapmaktadır. İngilizce bilmektedir. Evli ve bir çocuk babasıdır.