



HAVA FOTOĞRAFLARININ YAPAY SİNİR AĞLARI İLE SINIFLANDIRILMASI

ŞERİFE NALÇACIGİL

FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ
YÜKSEK LİSANS TEZİ

Tez Danışmanı: Doç. Dr. HALİS ALTUN

Mevlana Üniversitesi

2016

HAVA FOTOĞRAFLARININ YAPAY SİNİR AĞLARI İLE SINIFLANDIRILMASI

Mevlana Üniversitesi Fen Bilimleri Enstitüsü'nün 5001105 numaralı Yüksek Lisans Öğrencisi Şerife NALÇACIGİL, ilgili yönetmeliğin belirlediği gerekli tüm şartları sağladıktan sonra hazırladığı “ HAVA FOTOĞRAFLARININ YAPAY SİNİR AĞLARI İLE SINIFLANDIRILMASI ” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Jüri Üyeleri:

Doç. Dr. HALİS ALTUN

Doç. Dr. HAKAN KARABÖRK

Doç. Dr. ALAA ELEYAN

Yrd. Doç. Dr. ARMAĞAN ÖZKAYA

Bilgisayar Müh. Anabilim Dalı Başkanı

Prof. Dr. Ali SEBETCİ

Fen Bilimleri Enstitüsü Müdürü

Tarih: 17.02.2016

Bu tezdeki bütn bilgilerin etik davranıř ve akademik kurallar çerçevesinde elde edildiđini ve tez yazım kurallarına uygun olarak hazırlanan bu çalıřmada bana ait olmayan her türlü ifade ve bilginin kaynađına eksiksiz atıf yapıldıđını bildiririm.

řerife NALÇACIGİL

ÖZ

HAVA FOTOĞRAFLARININ YAPAY SİNİR AĞLARI İLE SINIFLANDIRILMASI

Şerife NALÇACIGİL

(Bilgisayar Mühendisliği) Yüksek Lisans Tezi, 2016

Tez Danışmanı: Doç. Dr. HALİS ALTUN

Anahtar kelimeler: Uzaktan Algılama, Görüntü, Yapay Sinir Ağları

ÖZET

Uzaktan algılama, belirli bir mesafeden bir takım araçlarla yeryüzündeki cisimlerin nitelik ve niceliklerinin ele alınmasıdır. Uzaktan algılamanın sonucunda elde edilen görüntülerin incelenmesinde ve yorumlanmasında en çok kullanılan method sınıflandırmadır. Sınıflandırma aslında bir karar mekanizması olmakla beraber, görüntü sınıflandırması ise piksellerin arazide karşılık geldiği değerlerin sınıflara atanmasıdır. Bu çalışmada çok katmanlı ileri beslemeli yapay sinir ağlarının etkin kullanımı için farklı topolojiler ile uygun ağ parametreleri ve giriş-çıkış modelleri incelenmiştir. Konya ili Beyşehir ilçesini ele aldığımız çalışmada farklı görüntülerden elde edilmiş veri seti kullanılmıştır. Yapılan çalışmalar 75-10-3 ağ yapısına sahip olan ve RGBTEKAĞ olarak adlandırılan modelin %95 başarı elde ettiği gözlemlenmiştir.

ABSTRACT

CLASSIFICATION OF AIR PHOTOS BY ARTIFICIAL NEURAL NETWORK

Şerife NALÇACIGİL

Master of Science Thesis in Computer Engineering

Supervisor: Assoc. Prof. HALİS ALTUN

Keywords: Remote Sensing, Image, Artificial Neural Network

ABSTRACT

Remote sensing is addressing the matter of qualification and quantity of the earth from a distance by some tools. The most important method to analyse and evaluate in remote sense is classification. Classification is a decision mechanism and in remote sensing it means assigning given pixels to the equivalent class. In this study, the Multi Layered Feed Forward neural network is used. The most suitable network structure and parameters are identified along with different input and output configuration. The database consists of images which are taken from Konya province Beyşehir district. It is found that the network which is called as RGBTEKAG with network structure of 75-10-3 gives the best result.

TEŐEKKÜR

Yapmış olduđum alıőmalar boyunca bilgi, gürüş ve yardımlarını her daim aktaran deđerli hocam Sayın Do. Dr. HALİS ALTUN'a, ayrıca Do. Dr. HAKAN KARABÖRK ve Do. Dr. ALAA ELEYAN'a teőekür ederim.

İTHAF

Hayatımın her anında beni maddi manevi destekleyen ve beni bugünlere getiren değerli annem Mukadder AKÜN'e ve babam Hayrettin AKÜN'e, beni kızları gibi görüp sevgilerini gösteren değerli annem Perihan NALÇACIGİL'e ve babam Şeref NALÇACIGİL'e bu tezi ithaf ediyorum.

İÇİNDEKİLER

ÖZ	i
ABSTRACT	ii
TEŞEKKÜR	iii
İTHAF	iv
İÇİNDEKİLER	v
ŞEKİLLER LİSTESİ	vi
TABLolar LİSTESİ	vii
BÖLÜM 1	8
1.1. Literatür Taraması.....	9
1.2. Uzaktan Algılama.....	9
1.3. Uzaktan Algılama Sistemleri.....	11
1.4. Sınıflandırma Yöntemleri.....	12
1.4.1. Kontrolsüz Sınıflandırma.....	12
1.4.2. Kontrollü Sınıflandırma.....	13
BÖLÜM 2	15
2. Yapay Sinir Ağları.....	15
2.1.1. Biyolojik Sinir Ağı.....	15
2.1.2. Yapay Sinir Ağı.....	16
2.1.3. İşlemci Eleman (Yapay Nöron).....	17
2.1.4. Aktivasyon Fonksiyonu.....	18
2.1.5. Yapay Sinir Ağlarının Sınıflandırılması.....	18
2.1.5.1. Yapay Sinir Ağlarının Yapılarına Göre Sınıflandırılması.....	18
2.1.5.1.1. İleri Beslemeli Ağlar.....	18
2.1.5.1.2. Geri Beslemeli Ağlar.....	18
2.1.5.2. Geri Yayılım Öğrenme Algoritması.....	20
BÖLÜM 3	21
3. Yapay Sinir Ağları ile Görüntü Sınıflandırma.....	21
3.1. Eğitim Verisinin Oluşturulması.....	22
3.2. Yapay Sinir Ağları Dizayn.....	27
3.2.1. RGBTEKAĞ Yapay Sinir Ağı.....	27
3.2.2. RGBUZMAN Yapay Sinir Ağı.....	30
3.3. Yapay Sinir Ağlarında Kullanılan Parametreler.....	32
BÖLÜM 4	34
4. Sınıflandırmadan Elde Sonuçlar.....	34
4.1. Doğruluk Analizi.....	35
4.2. Yapılan Analizlerin Sonuçları.....	37
4.3. Hava Fotoğraflarının Sınıflandırılması İle Elde Edilen Sonuçlar.....	40
4.4. SONUÇ.....	44
KAYNAKLAR	45

ŞEKİLLER LİSTESİ

Şekil 1. 1 : Uzaktan Algılama Modeli.....	10
Şekil 1. 2 : Uzaktan Algılama Sistemi Bileşenleri	11
Şekil 1. 3 : Piksel – Dijital Değer.....	12
Şekil 1. 4 : Kontrolsüz Sınıflandırma.....	13
Şekil 1. 5 : Kontrollü Sınıflandırma	14
Şekil 2. 1 : Biyolojik Sinir Ağı Yapısı	15
Şekil 2. 2 : Yapay Sinir Ağı Modeli.....	16
Şekil 2. 3 : Yapay Sinir Hücresi Elemanları	17
Şekil 2. 4 : Geri Yayılım Öğrenme Algoritması	20
Şekil 3. 1 : Yapay Sinir Ağları ile Sınıflandırma Yapısı.....	21
Şekil 3. 2 : Beyşehir İlçesine ait Hava Fotoğrafı.....	22
Şekil 3. 3 : Erdas İmagine, Eğitim Setlerinin Oluşumu	23
Şekil 3. 4 : Görüntü Band İçeriği	23
Şekil 3. 5 : Eğitim Seti Örnekleri	23
Şekil 3. 6 : Tarım Alanı (Kırmızı Kare) ve Göl (Mavi Kare) Eğitim Noktaları	24
Şekil 3. 7 : Bina (Yeşil Kare) eğitim Noktaları.....	24
Şekil 3. 8 : Eğitim ve Test Verileri Alınma Yöntemi MATLAB.....	25
Şekil 3. 9 : Eğitim Veri Seti Matlab	25
Şekil 3. 10 : Verilerin elde Ediliş Şeması.....	25
Şekil 3. 11 : Matlab Pixel Seçim	26
Şekil 3. 12 : Seçilen Pixele Göre Komşu Pixellerden Matris Oluşumu.....	26
Şekil 3. 13 : RGBTEKAĞ Yetmişbeş Girişli Tek Çıkışlı Yapay Sinir Ağı.....	27
Şekil 3. 14 : RGBTEKAĞ Yetmişbeş Girişli Üç Çıkışlı Yapay Sinir Ağı	28
Şekil 3. 15 : RGBTEKAĞ Üç Girişli Tek Çıkışlı Yapay Sinir Ağı.....	28
Şekil 3. 16 : RGBTEKAĞ Altı Girişli Tek Çıkışlı Yapay Sinir Ağı	29
Şekil 3. 17 : RGBUZMAN (Her Bir Ağ) Yetmişbeş Girişli Tek Çıkışlı Yapay Sinir Ağı	30
Şekil 3. 18 : RGBUZMAN (Her Bir Ağ) Yetmişbeş Girişli Üç Çıkışlı Yapay Sinir Ağı	31
Şekil 3. 19 : Kullanılan Ağ Yapısındaki Ara Katmanlar ve Fonksiyonlar.....	32
Şekil 4. 1 : Konya Beyşehir İlçesine Ait Test İçin Seçilen Görüntüler.....	40
Şekil 4. 2 : RGBUZMAN Tek çıkışlı Sınıflandırma.....	40
Şekil 4. 3 : RGBUZMAN Tek çıkışlı Sınıflandırma Sonuç.....	41
Şekil 4. 4 : RGBTEKAG Tek Çıkışlı Sınıflandırma	41
Şekil 4. 5 : RGBTEKAG Üç Çıkışlı Sınıflandırma	41
Şekil 4. 6 : RGBUZMAN Üç Çıkışlı Sınıflandırma	42
Şekil 4. 7 : RGBUZMAN Üç Çıkışlı Sınıflandırma Sonuç	42
Şekil 4. 8 : RGBTEKAĞ Üç Girişli Tek Çıkışlı Sınıflandırma	42
Şekil 4. 9 : Beyşehir İlçesi Toprak Yoğunlukları.....	43

TABLolar LİSTESİ

Tablo 2. 1 : Sinir Sistemi ile Yapay Sinir ağlarının Karşılaştırılması.....	17
Tablo 2. 2 : Aktivasyon Fonksiyonları.....	19
Tablo 4. 1 : Test İşlemi Sonuçları	34
Tablo 4. 2 : Test İşlemi Sonuçları	35
Tablo 4. 3 : Hata Matrisi	35
Tablo 4. 4 : Kappa İstatiksel Değer Yorumları	37
Tablo 4. 5 : RGBTEKAĞ Tek Çıkışlı Hata Matrisi (75-10-1)	37
Tablo 4. 6 : RGBUZMAN TEK Çıkışlı Hata Matrisi (75-10-1).....	38
Tablo 4. 7 : RGBTEKAĞ Üç Çıkışlı Hata Matrisi (75-10-3).....	38
Tablo 4. 8 : RGBUZMAN Üç Çıkışlı Hata Matrisi (75-10-3).....	39
Tablo 4. 9 : RGBTEKAĞ Üç Girişli Tek Çıkışlı Hata Matrisi (3-10-1)	39

BÖLÜM 1

GİRİŞ

Uydu görüntülerinden veya hava fotoğraflarından yeryüzüne ait bilgilerin elde edilmesinde en çok başvurulan yöntem görüntülerin sınıflandırılmasıdır. Sınıflandırma bir karar verme işlemi olmakla beraber; amaç ele alınan bütün piksellerin karşılık geldikleri sınıflar içine otomatik olarak atamak ve yerleştirmektir.

İnsan beynini örnek alan yapay sinir ağları birbirine bağlanmış nöronlardan meydana gelmektedir. Bilgi alınır, transfer fonksiyonu uygulanarak işlemler yapılır ve bir sonuç üretilir.

Yapay sinir ağları ile sınıflandırmanın kullanılmasındaki avantajlar birisi , yapay sinir ağlarının da özelliği olan, ön bir bilgiye gerek duyulmadan sınıflandırılmanın yapılmasıdır. Yani öğretilme ve öğrenme ile farklı farklı durumlara cevap verilebilmesi, parametrik bir yapıya sahip olmamasıdır. Gürültüyü tolere edebilmeleri ve en önemlisi öğrenebilme (genelleme) kabiliyetlerinden dolayı oldukça büyük bir ilgi odağı olmuştur. Karar sınırları veri dağılımı ne olursa olsun orijinal veri dağılımına uyacak şekilde ağı eğitilmesiyle dengelenir.

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

1.1. Literatür Taraması

Uzaktan algılama alanında literatürde yapılan çalışmalar oldukça uzun zamandan beri araştırmacıların ilgi alanındadır, Landsat uydu görüntüsü üzerindeki ilk sınıflandırmayı 1970'li yıllarda Huang, Davis ve Townshend yapmıştır. Genel olarak literatürde karşılaşılan bu çalışmalar parametrik teknikler; Öklit (Ecludian), Mahalanobis, En Çok Benzerlik Yöntemi (Maximum Likelihood) gibi yöntemler ve parametrik olmayan yaklaşımlar; Yapay Sinir Ağları, Karar Ağaçları, Destek Vektör Makinaları şeklinde temel olarak iki gruba ayrıştırılabilir.

Bu yöntemler arasından makine öğrenimleri olarak tanımlanabilecek olan Yapay Sinir Ağları, Karar Ağaçları, Destek Vektör Makinaları son yıllarda daha yoğun olarak kullanılmıştır [20].

Yapay Sinir Ağları kapsamında ise literatürde yoğun olarak rastlanılan; çok katmanlı perseptron (ileri beslemeli ağ), Delta kuralı (kontrollü öğrenme), Hopfield, Elman ve Jordan (Geri beslemeli ağ), ART ve SOM (Kontrolsüz öğrenme) gibi farklı ağ modelleri ve eğitim algoritmaları kullanılmıştır .


Hepner ve Ritter [21], Dreyer [22] yapay sinir ağları ile uydu görüntüsünü sınıflandırmıştır. Omatu and Yosida [23] çalışmalarında istatiksel metod olan Bayes Sınıflandırıcıdan yapay sinir ağlarının daha performanslı çalıştığını görmüşlerdir.

Kanellopoulos [24] , Kavzoğlu [13] SPOT uydu görüntülerinde yapay sinir ağı metodunun En Çok Benzerlik yönteminden (Maximum Likelihood) daha başarılı sonuç verdiğini görmüştür. Kansu [25] tarafından yapılan çalışmalarda IKONOS ve Landsat uydu görüntülerinde yapay sinir ağları yönteminin, maksimum olabilirlik yöntemi ve bulanık mantık yöntemlerinden daha başarılı olduğu sonucuna varılmıştır. Çetin, Kavzoğlu ve Musaoğlu [26] tarafından yapılan çalışmalarda ise Landsat ETM+ ve Terra ASTER uydu görüntülerinde yapay sinir ağlarının En Çok Benzerlik yönteminden (Maximum Likelihood) daha iyi olduğu görülmüştür. Chitwong, Witthayapradit, Intajag, Cheevasuvit geri beslemeli yapay sinir ağının En Çok Benzerlik yöntemine kıyasla daha iyi olduğu anlaşılmıştır [27].

1.2. Uzaktan Algılama

Uzaktan Algılama; mekanik bir temas olmadan cismin nitelik ve nicelik yönünden ele alınması ve özelliklerinin ölçülmesidir [1]. Başka bir deyişle, yeryüzünden belli bir uzaklıkta atmosferde ve uzaydaki platformlara yerleştirilmiş aletlerle bilgi alma ve bunları değerlendirme tekniğidir.

Uzaktan algılama tarihi 1960 yılında, Evelyn L. Pruitt ile başlamıştır. Modern uydu algılama teknolojilerinin en önemli uygulamalarından biri, arazi örtüsü kullanımının uzaktan algılama ile haritalanması ve harita bilgilerinin üretilmesidir. Ekonomik, çevresel ve sosyal koşulların değişimini yansıtan arazi kullanımının günden güne farklılaşan biçimleridir. Dolayısı böyle değişimlerin izlenmesi uluslar için her zaman önemli olmuştur.



Şekil 1.1 : Uzaktan Algılama Modeli

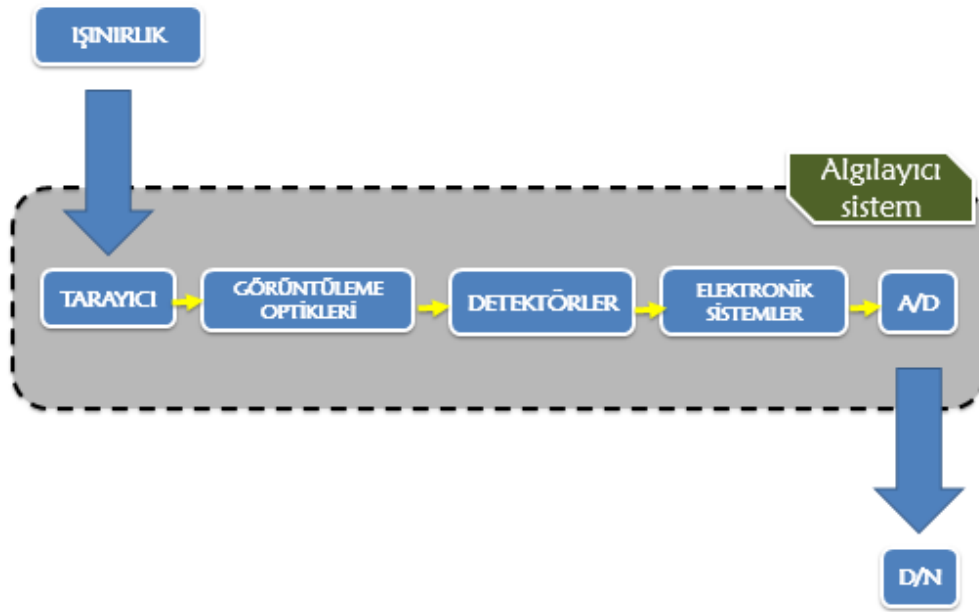
Uzaktan algılama sistemlerinde bulunan yedi adım Şekil 1.1’de gösterilmiştir;

1. Uzaktan algılamada en önemli unsurlardan biri enerji kaynağıdır ve verilerin alınması istenen objelere elektro manyetik enerji sağlar.
2. Enerji kaynağından çıkarak yeryüzünde bulunan objelere daha sonrada yansıyarak sensörlere gelen enerji atmosferle sürekli olarak etkileşimdedir.
3. Nesnelere ile ilgili bilgi, bu etkileşim ve yansıma sonucunda oluşur.
4. Sensörler nesnelere emilme, iletme, yansıma sonrasında gelen elektromanyetik enerjiyi kayıt altına alırlar.
5. Kayıt altındaki bu veriler bir istasyonda işlenir daha sonra ise görüntüye dönüştürülebilmesi için gönderilirler.
6. Sonuçta ortaya çıkan görüntüler bilgi edinebilmek amacıyla görsel veya bilgisayar yazılımlarıyla analiz edilir ve yorumlanırlar.
7. Son olarak ise yapılan analizler ve yorumlamalar kullanılmak suretiyle, yeni bilgiler ortaya çıkmış olur. Böylece sorun için çözüm sağlanmış olur.

Uzaktan algılama da, uydular veya hava araçları üzerinde taşınan aletlerle yapılan gözlem ve ölçümler dikkate alınmaktadır. Elektromanyetik enerjiden, uydular ya da hava araçları üzerinde bulunan aletlerle yapılan ölçümlerde faydalanılır [2].

1.3. Uzaktan Algılama Sistemleri

Uzaktan algılama sistemleri yansıtılan veya yayılan ışınırılığı, ışınırılığın uzaysal dağılımını oluşturan görüntüye dönüştürür. Bu dönüşüm aşamasında algılanan ışınırılığın radyometrik geometrik ve uzaysal özelliklerinde önemli dönüşümler yapılır. Bu dönüşümler sonucunda toplam ışınırılığın ilgilenilen kısmındaki sinyalde bozulmalar oluşur. Bu bozulmanın karakterinin anlaşılması görüntü işleme algoritmalarının düzenli tasarlanması ve görüntülerin yorumlanması açısından önemlidir [3].




Şekil 1. 2 : Uzaktan Algılama Sistemi Bileşenleri

Şekil 1.2’de görülen uydu sistemi yapısında; İlgilenilen objeyle uydu sistemi arasında bilgi iletimini sağlayan Elektro Manyetik Radyasyon (EMR), detektörlerce algılanır ve elektron akımına saptanabilir diğer elektriksel işaretlere dönüştürülür. Tarama işlemiyle sürekli zamansal elektronik sinyale dönüştürülen uzaysal bilgi daha sonra A/D (Analog /Dijital) dönüştürücülerle işlenerek görüntü piksellerini temsil eden ayrık dijital sayılara (DN) kuantalanır.

Hava fotoğrafı ise film ve filtrelerin uçaklara yerleştirilmesi ile yeryüzündeki nesnelere yansıyan ışığın algılayıcılar tarafından saptanması ile elde edilen görüntüdür.

Uzaktan Algılama sonrasında görüntüler dijital olarak kayıt altına alınır. Bilgisayarlar ile görüntüye dönüştürülmek üzere işlenir. Uzaktan algılama sisteminde algılayıcı enerjiyi algılar, ölçer ve miktarını bilgisayarın okuyabilmesini sağlayacak bir sayıya çevirir. Uzak araçları bu kodları sinyaller halinde yeryüzündeki uydu yer istasyonuna gönderir. Alınan

sinyaller ile bir dijital görüntü oluştururlar. Yani sayılar küçük resim elemanlarına çevrilip bir araya geldiklerinde görüntünün tamamını oluştururlar.



Şekil 1.3 : Piksel – Dijital Değer

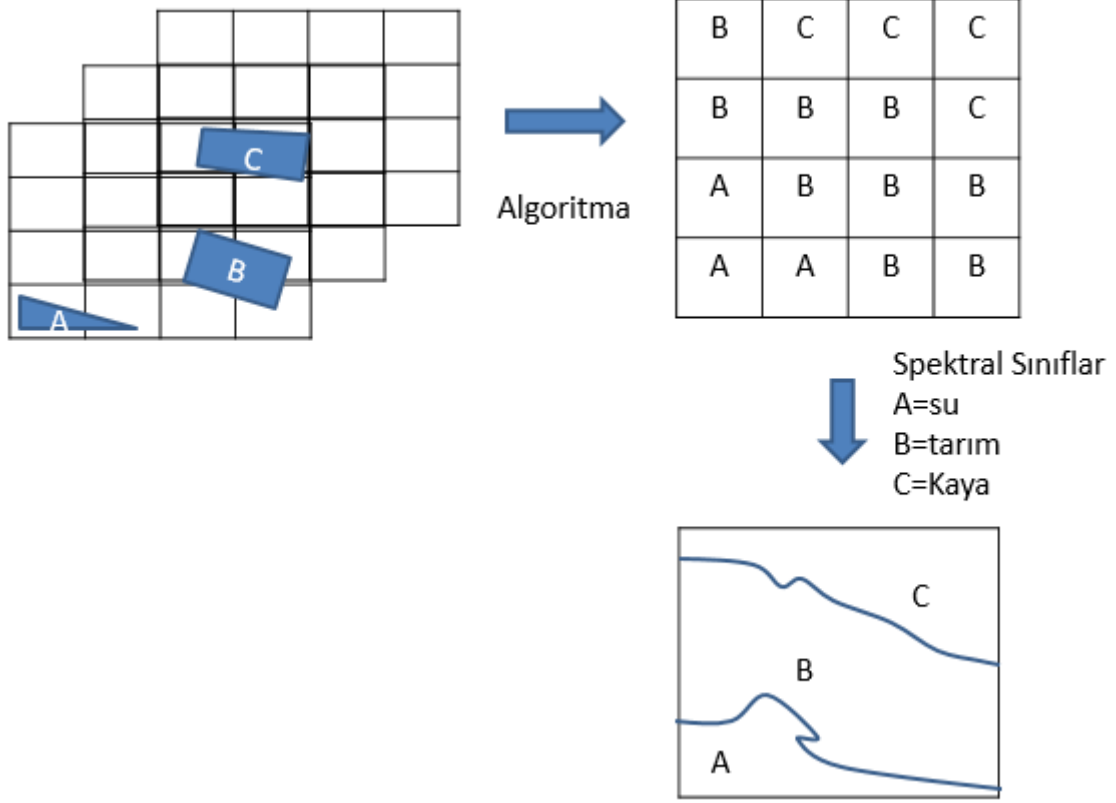
Dijital görüntüyü oluşturan resim elemanlarına piksel adı verilir. Piksele ait olan değer dijital değer (DN) ile gösterilir Şekil 1.3. DN değerleri genellikle 0-255 arasındadır.

1.4. Sınıflandırma Yöntemleri

Literatürde Uzaktan Algılama problemi çerçevesinde kullanılan Makine Öğrenmesine dayalı sınıflandırma yöntemleri genel olarak iki gruba ayrıştırılabilir: (a) Kontrolsüz sınıflandırma, (b) Kontrollü sınıflandırma

1.4.1. Kontrolsüz Sınıflandırma

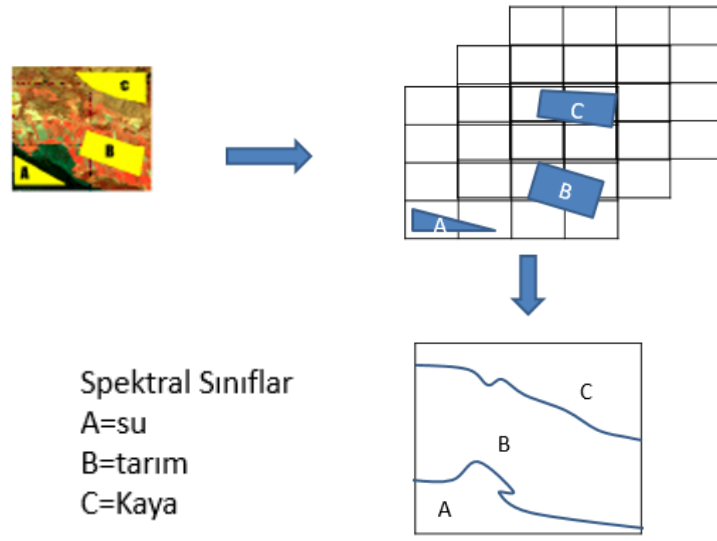
Eğitim setlerinin sınıflarının bilinmesi durumunda veya bu eğitim setlerinin olasılık dağılım bilgisinin olmadığı durumlarda yani görüntü içerisinde veri tanımlaması yapılamadığında kümeleme adı verilen metodlar ile yapılan sınıflandırmalardır. Şekil 1.4’de görüldüğü gibi eğitimsiz sınıflandırma iki aşamadan oluşmaktadır. İlk olarak veri kümelerine ayrılır. Benzer nesnelere alınan spektral değerler yakın bir gruplaşma içindedir. Eğitimsiz sınıflandırma sonucunda spektral sınıflar ortaya çıkar. Daha sonra, büyük ölçekli harita yada görüntü gibi referans verileri ile sonuçta ortaya çıkan spektral sınıflar karşılaştırılarak yeryüzünde hangi nesneye karşılık geldikleri belirlenir [4] [5].



Şekil 1. 4 : Kontrolsüz Sınıflandırma

1.4.2. Kontrollü Sınıflandırma

Kontrollü sınıflandırmada spektral olan sınıflara karar verilir. Sonrasında bu spektral sınıflara ait bilgiler alınır. Şekil 1.5’de görüldüğü gibi eğitilmiş sınıflandırma üç adımdan oluşur; eğitim adımı, sınıflandırma adımı ve çıktı adımı. Eğitim aşamasında eğitim alanları belirlenir. Eğitim alanları yeterli düzeyde olmalıdır. Sınıflandırma aşamasında eğitim alanlarından alınan verilerin her bir sınıf ile kıyaslanıp, en çok hangi sınıfa benzediği bulunur. Kullanılan yöntemler; Ortalamaya En Az Uzaklık Yöntemi, Paralel kenar Yöntemi, En Yüksek Olasılık Yöntemi ve ayrıca Yapay Sinir Ağlarına dayalı yöntemlerdir [6].




Şekil 1.5 : Kontrollü Sınıflandırma[6]

BÖLÜM 2

2. Yapay Sinir Ağları


1949 yılında Donald Hebb Sinir ağına ilk çalışmalara başlayan bilim adamıdır. Nörolog olan Hebb, beyin ile ilgili olan çalışmalar yapmış ve beynin birimlerinden olan sinir hücrelerini incelemiştir. Sinir hücrelerinin birbirleriyle olan ilişkilerini incelemiş ve sinir ağı teorisinde bu bilgilerden yola çıkmıştır. Günümüzde yapay sinir ağları üzerinde yapılan çalışmalar sonucunda oldukça güçlü ağ ve algoritmalar geliştirilmiştir. Geliştirilen bu yöntemlere dayalı olarak yapılan çalışmalarda oldukça yüksek başarı oranlarına ulaşıldığı literatürde verilmiştir [7].

2.1.1. Biyolojik Sinir Ağı



Şekil 2. 1 : Biyolojik Sinir Ağı Yapısı[10]

Şekil 2.1 'de görüldüğü gibi, biyolojik sinir ağları, dendrit, soma, akson gibi birimlerden müteşekkildir. Dendrit, başka sinir hücrelerinden gelen sinyalleri, o sinir hücresinin çekirdeğine iletmektedir. Soma, dendritler vasıtası ile iletilen bütün sinyalleri alıp toplayan bir merkezdir. Diğer bir adı da hücre çekirdeğidir. Çekirdek, toplanan sinyallerin diğer sinir hücrelere iletilmesi için bilgiyi aksona iletir. Akson, hücre çekirdeğinin tarafından alınan toplam bilgiyi bir diğer sinir hücreğine iletmekle yükümlüdür. Bu toplam bilgi sinapsislerde ön işleme tabi tutularak diğer sinir hücrelerinin dendritlerine aktarılır. Bu ön işlem önemlidir. Çünkü toplam sinyal yalın bir halde değilse, belli bir aralığa çekilerek diğer sinir hücrelerine aktarılmış olur. Böylece, toplam sinyaller ile dentrite iletilen sinyaller arasında bir bağlantı kurulmuş olur.



Şekil 2.2 : Yapay Sinir Ağı Modeli

Dolayısı ile “öğrenme” işleminin sinapsislerde gerçekleştiği fikri savunulmuş ve bu da şu an kullanılmakta olan yapay sinir ağı dünyası için teori haline gelmiştir. Şekil 2.2. Bu teori ile birlikte yapay sinir ağı modellemesinde “öğrenme”, sinapsisler ile dendritler arasındaki ağırlık katsayılarının güncellenmesi olarak algılanmaktadır Şekil 2.2 [7].

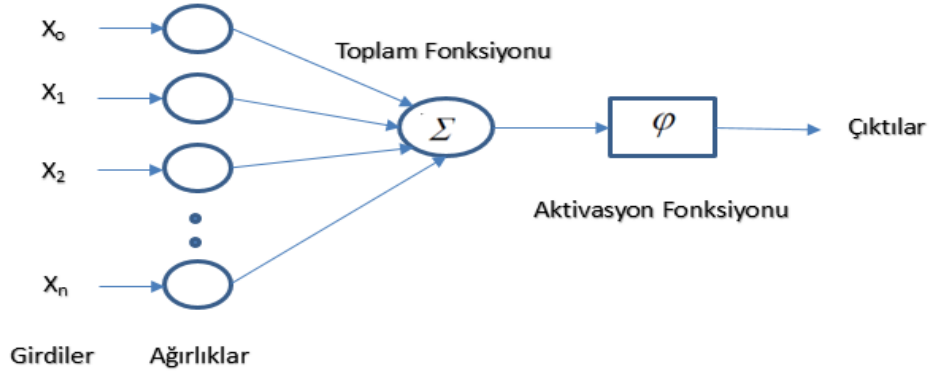
2.1.2. Yapay Sinir Ağı

Yapay sinir ağları paralel bir yapıya sahiptir. Ağ yapısı birbirine bağlanan işlem elemanlarından oluşur. Çıkış işareti isteğe göre değişebilir. Ağlar çevre şartlarına göre davranışlarını değiştirebilir.

Yapay sinir ağları yapısı itibariyle çok hücreden oluşur. Bu hücreler eş zamanlı olarak faaliyet gösterir. Bu hücrelerden birinin işlevini kaybetmesi sistemin çalışmasına engel teşkil etmez. Bu da hata toleranslı olduklarını gösterir. Yapay sinir ağları makina öğrenmesi gerçekleştirebilirler. Öğrendikleri şekle uyum gösteren olaylarla ilgili karar verebilirler. Genel olarak yapılan programlamalardaki gibi veriler veri tabanı yada dosyalarda tutulmaz, ağın bütündeki bağlantılarında saklanmaktadır.

Dağıtık belleğe sahip olan yapay sinir ağlarında bilgiler ağ yapısına dağılmış bir şekilde tutulur. Dolayısı ile tek bir bağlantının kendi başına anlamı yoktur. Yapay sinir ağlarında öğrenme işlemi için eğitim verilerinin belirlenmesi, bunların ağa verilerek hedef çıktılara göre ağın eğitilmesi gerekmektedir. Seçilen eğitim verilerinin uygun veriler olması eğitimde istenen sonucu yakalamak için önemlidir. YSA'lar eğitimleri sırasında kendilerine verilen örneklerden elde ettikleri genellemeler ile yeni örnekler hakkında bilgi verilirler [8].

2.1.3. İşlemci Eleman (Yapay Nöron)



Şekil 2. 3 : Yapay Sinir Hücresi Elemanları

Şekil 2.3’de gösterildiği gibi yapay sinir ağları girdiler, ağırlıklar, toplam fonksiyonu, aktivasyon fonksiyonu ve çıktılarından oluşmaktadır. Girdiler işlemci elemana gelen verilerdir. Girdiler yapay sinir hücresine bir diğer hücreden gelebileceği gibi direk olarak dış veri olarak da gelebilir. Yapay sinir hücresine gelen veriler, çekirdeğe gitmeden önce geldikleri ağların ağırlığıyla çarpılarak çekirdeğe iletilirler. Böylece girdilerin üretilecek çıktı üzerindeki etkisi ayarlanabilmektedir. Ağırlık değerleri pozitif, negatif ya da sıfır olabilir. Yapay sinir hücresinde, ağırlıklarla çarpılarak gelen girdileri toplayıp o hücrenin net girdisini hesaplayan fonksiyon toplama fonksiyonudur [8]. Tablo 2.1’de sinir sistemi ve yapay sinir ağları karşılıkları görülmektedir.

Tablo 2. 1 :Sinir Sistemi ile Yapay Sinir ağlarının Karşılaştırılması

SİNİR SİSTEMİ	YSA SİSTEMİ
Nöron	İşlem elemanı
Dentrit	Toplama fonksiyonu
Hücre Gövdesi	Transfer Fonksiyonu
Aksonlar	Eleman Çıkışı
Sinapslar	Ağırlıklar

2.1.4. Aktivasyon Fonksiyonu

Yapay sinir hücrelerine giren net girdiyi hesaplayarak, bu girdiye karşılık üretilmesi gereken çıktıyı belirler. Yapay sinir ağlarının “doğrusal olmama” özelliği aktivasyon fonksiyonlarının doğrusal olmama özelliğinden gelmektedir. Literatürde en yaygın olarak kullanılan aktivasyon fonksiyonları Tablo 2.2 de verilmiştir. “Çok katmanlı algılayıcı” modelinde ise genelde aktivasyon fonksiyonu olarak “Sigmoid” fonksiyonu kullanılır [8].

2.1.5. Yapay Sinir Ağlarının Sınıflandırılması

Yapay sinir ağları genelde birbirleriyle bağlantılı olan işlemci elemanlardan yada yapay nöronlardan oluşur. Nöronlar arası bağlantıların nasıl olduğu ve bağlantıların karakteri yapay sinir ağının karakterini belirler. Sinaptik ağırlıkların, yapay sinir ağının ulaşması istenen davranışı elde edecek şekilde güncellenmesi veya eğitilmesi öğrenme algoritmasıyla gerçekleştirilir. YSA'lar, yapılarına ve öğrenme algoritmalarına göre sınıflandırılabilir [9].

2.1.5.1. Yapay Sinir Ağlarının Yapılarına Göre Sınıflandırılması

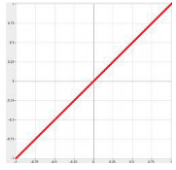
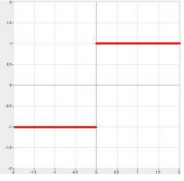
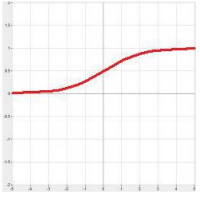
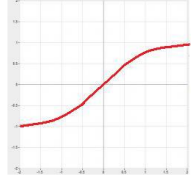

2.1.5.1.1. İleri Beslemeli Ağlar

İleri beslemeli bir ağda işaretler, giriş katmanından çıkış katmanına doğru tek yönlü bağlantılarla iletilirken aynı katman içinde bağlantıları yoktur. Örnek olarak çok katmanlı algılayıcı (Multi Layer Perseptron-MLP) ağı verilebilir.

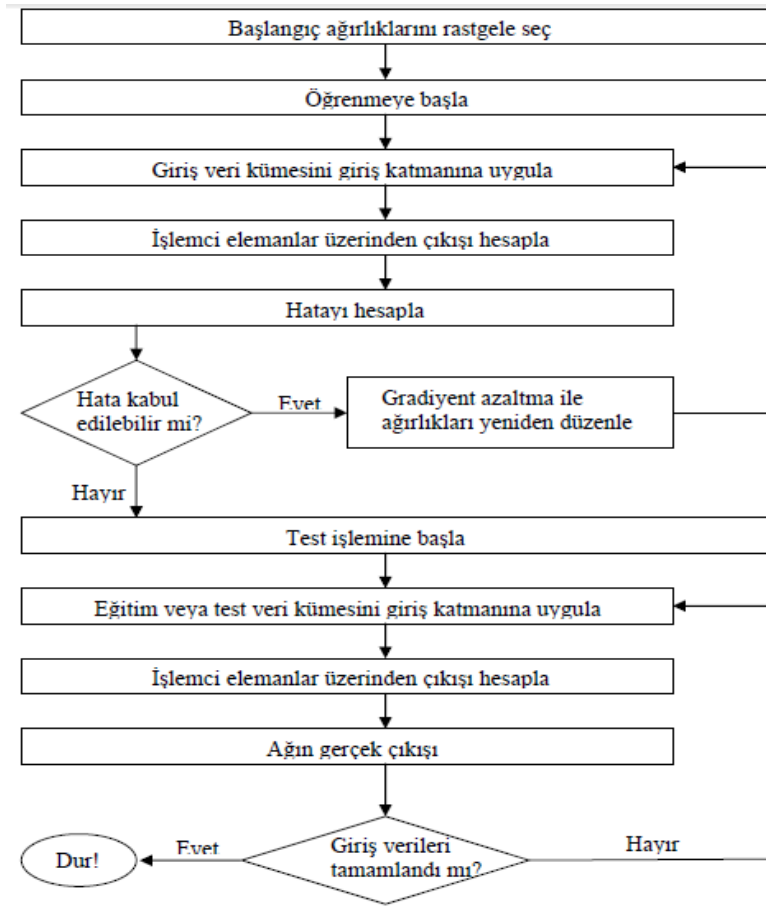
2.1.5.1.2. Geri Beslemeli Ağlar

Geri beslemeli YSA' larda, bazı nöronların çıkışları, aynı nörona veya önceki katmanlardaki nöronlara geri beslenir. Dolayısıyla, girişler hem geri, hem de ileri yol izlemiş olur. Böylece dinamik bir yapı kazanırlar.

Tablo 2. 2 :Aktivasyon Fonksiyonları

Doğrusal (Lineer) Aktivasyon Fonksiyonu		$F(\text{NET})=A * \text{NET}$ (A sabit bir sayı)	Doğrusal problemlerde kullanılır. Toplama fonksiyonu sonucu, belli bir katsayı ile çarpılarak hücrenin çıktısı hesaplanır.
Adım (Step) Aktivasyon Fonksiyonu		$F(\text{Net})= \begin{cases} 1 & \text{if Net} > \text{Eşik Değer} \\ 0 & \text{if Net} \leq \text{Eşik Değer} \end{cases}$	Net girdilerin belli bir değerinin altında yada üstünde olmasıyla hücrenin çıktısı 1 veya 0 olarak değer alır.
Sigmoid Aktivasyon Fonksiyonu		$F(\text{Net})= \frac{1}{1+e^{-\text{Net}}}$	Sigmoid fonksiyonu türevi alınabileni sürekli bir fonksiyondur. Doğrusal olmadığından yapay sinir ağlarında sıkça kullanılır. Bu fonksiyon girdi değerlerinin her biri için 0 ile 1 arasında bir değer üretir.
Tanjant Hiperbolik Aktivasyon Fonksiyonu		$F(\text{Net})= \frac{e^{\text{Net}} + e^{-\text{Net}}}{e^{\text{Net}} - e^{-\text{Net}}}$	Tanjant fonksiyonu, sigmoid fonksiyonuna benzerlik gösterir yalnız Sigmoid fonksiyonunda çıkış değerleri 0 ile 1 arasında değişirken hiperbolik fonksiyonunda bu değerler -1 ile 1 arasında değişmektedir.
Sinüs Aktivasyon Fonksiyonu		$F(\text{Net}) = \text{Sin}(\text{Net})$	Öğrenilmesi gereken olaylarda sinüs fonksiyonuna uygun dağılım gösteren durumlarda kullanılır.

2.1.5.2. Geri Yayımlı Öğrenme Algoritması



Şekil 2. 4: Geri Yayımlı Öğrenme Algoritması[10]

Literatürde en sık olarak kullanılan Çok Katmanlı Perceptron ağlarının eğitiminde geri yayımlı öğrenme algoritması genellikle kullanılan bir eğitim algoritmasıdır. Bu algoritmanın akış diyagramı Şekil 2.4’de verilmiştir.

Bir geri beslemeli sinir ağı, çıkış ve ara katlardaki çıkışların, giriş birimlerine veya önceki ara katmanlara geri beslendiği bir ağ yapısıdır. Bu çeşit sinir ağlarının dinamik hafızaları vardır ve bir andaki çıkış hem o andaki hem de önceki girişleri yansıtır. Bundan dolayı, özellikle önceden tahmin uygulamaları için uygundur [10].

Geri beslemeli bir ağda, geri besleme olayı bir geciktirmeyi sağlayan eleman üzerinden yapılırken, hücrenin çıkışı ise kendisine veya başka hücrelere giriş olarak verilir. Geri besleme, katmanda bulunan hücreler arasında olabilir veya katmanlar arasında bulunan hücrelerde de olabilir. Böyle bir yapı ile beraber doğrusal olmayan dinamik bir durum sergiler. Geri beslemenin yapıldığı şekle göre farklı davranış ve yapıda geri beslemeli ağla elde edilebilir[10].

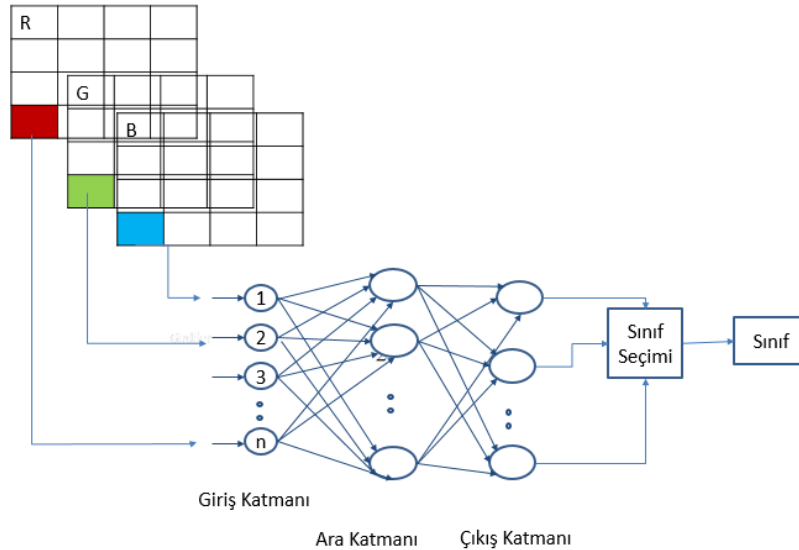
BÖLÜM 3

3. Yapay Sinir Ağları ile Görüntü Sınıflandırma

Yapay sinir ağları parametrik olmayan yani istatistiksel bir veri gerektirmeden yapılan bir sınıflandırma algoritmasıdır. Kontrollü öğrenme yönteminde, ağırlık değerleri güncellenmesi üretilen çıkışların hedef değerlerle eşleştirilmesiyle elde edilen hata değerinin minimize edilmesiyle yapılmakta iken, kontrolsüz öğrenme işleminde, ağırlık değerleri giriş için verilen örneğe benzer değeri üreten elemanın aktif olması yoluyla güncellenmektedir [10].

Uzaktan algılanmış görüntülerin yapay sinir ağları ile sınıflandırılmasında ölçekleme önemlidir. Çünkü daha geniş bir aralıkta olan veri daha dar bir aralığa indirgenebilmektedir. Böylece işlemler daha hızlı ve kolay yapılabilir. Sigmoid ve TANH fonksiyonlarının sıkıştırma etkisi ile de ağın performansı artmaktadır [11].

Ağa tanımlanacak olan çıkış verilerinin değerlerinin kodlanmasında kullanılan yöntemlerden biri her sınıf için ayrı bir çıkış elemanı kullanılmasıdır çünkü pikseller maksimum değer alan çıkış elemanına yani sınıfa atanır. Maksimum değer, ilgili olan pikselin büyük bir doğrulukla o sınıfa ait olduğunu gösterir [12]. Ağdaki giriş ve çıkış katmanlarındaki işlemci sayıları, kullanılan verinin boyutu ve sınıflandırmak istenen sınıf sayısına göre değişirken, gizli katmanlardaki elemanların sayısı yapılan denemelerle ortaya çıkmaktadır [13].




Şekil 3. 1 : Yapay Sinir Ağları ile Sınıflandırma Yapısı

Genel olarak YSA eğitimi için, Şekil 3.1’de görüldüğü gibi şu yollar izlenmektedir:

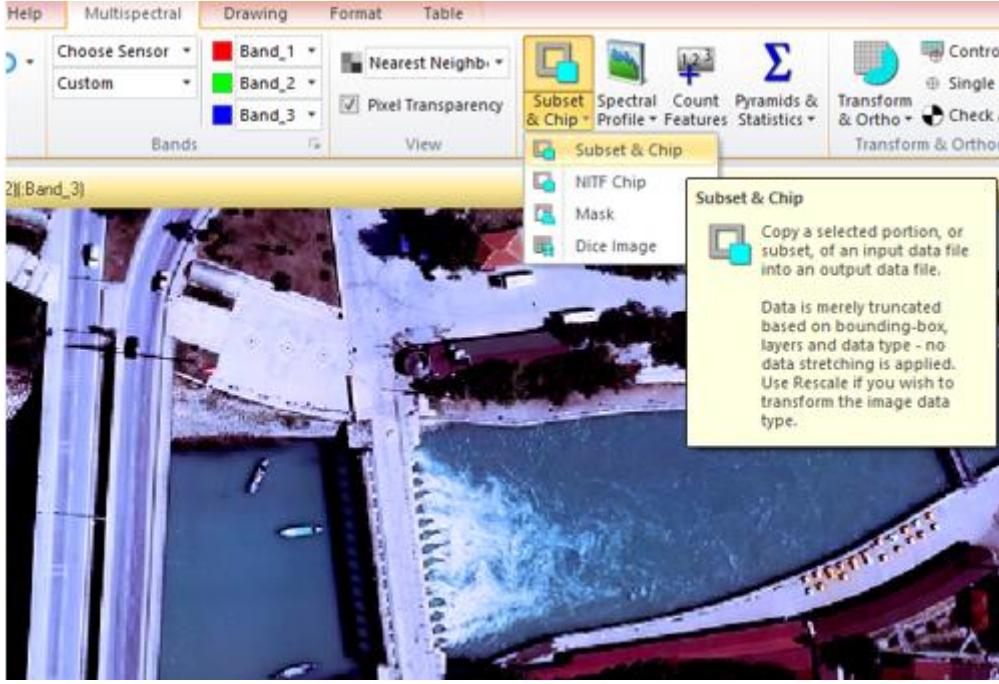
Eđitim, test ve hedef verilerinin belirlenmesi, ađda kullanılacak olan giriř, ıkıř ve ara katmanların sayılarının belirlenmesi, momentum oranı, đrenme hızı gibi parametrelere deđerlerin atanması, sınıflandırma iin gerekli olan ıkıř kodlarının verilmesi.

3.1. Eđitim Verisinin Oluřturulması


İlk adım yapay sinir ađlarında sınıflandırma da kullanılmak üzere eđitim veri setinin hazırlanmasıdır [14]. Őekil 3.2'deki grnt verimiz ECW formatında olup ERDAS IMAGINE programı ile grntlenebilmektedir. Setiđimiz bu grnt Konya'nın Beyřehir ilesinin hava fotođrafıdır.



Őekil 3. 2 : Beyřehir İlesine ait Hava Fotođrafı



Şekil 3. 3 : Erdas İmagine, Eğitim Setlerinin Oluşumu




Şekil 3. 4 : Görüntü Band İçeriği

Şekil 3.3' de görüldüğü üzere Erdas Imagine Programı ile belirli bir ölçekde sınıflarımızın eğitim setleri oluşturulmaktadır. Bu fotoğraflar R, G, B olmak üzere 3 bandlıdır Şekil 3. 4.



Şekil 3. 5 : Eğitim Seti Örnekleri

Eğitim verilerimiz Şekil 3.5 deki gibi bina, tarım alanı ve göl olmak üzere 3 sınıftan oluşmaktadır.



Şekil 3. 6 : Tarım Alanı (Kırmızı Kare) ve Göl (Mavi Kare) Eğitim Noktaları



Şekil 3. 7 : Bina (Yeşil Kare) eğitim Noktaları

Şekil 3.6 ve Şekil 3.7’de Eğitim noktalarından bazılarına yer verilmiştir.

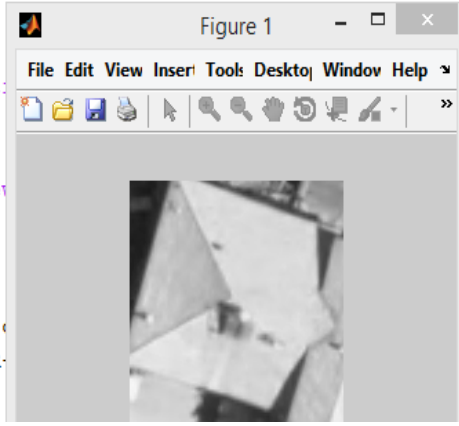
```

% train için değer alıyoruz
srcFiles = dir('D:\ORTOFOTO\newdata\t:

for i = 1 : length(srcFiles)
    filename = strcat('D:\ORTOFOTO\newdata\t:
    I = imread(filename);

    [cR,rR,pR]=impixel(I(:,:,1));
    x=[cR-2,cR-1,cR,cR+1,cR+2,cR-2,cR-3,cR-4];
    y=[rR-2,rR-2,rR-2,rR-2,rR-2,rR-2,rR-2,rR-2];
    pixels = impixel(I,x,y);

```

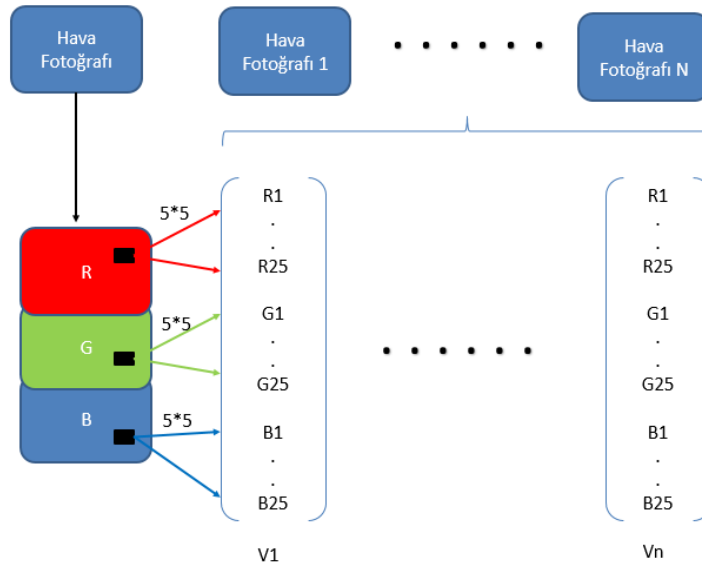


Şekil 3. 8 : Eğitim ve Test Verileri Alınma Yöntemi MATLAB

Eğitim ve test verilerimiz hazırlanırken MATLAB programının **impixel** fonksiyonu kullanılarak seçilen piksel değeri ve etrafında bulunan komşu piksel değerleri 5×5 lik matrisler halinde alınmıştır. Bu süreç ile ilgili kod ve ekran görüntüsü Şekil 3.8’da verilmiştir.

	1	2	3	4	5	6	7	8	9	10	11
1	148	134	87	113	118	125	127	157	87		
2	140	132	87	52	116	127	161	163	81		
3	138	139	87	76	114	126	134	161	122		
4	136	121	102	124	116	128	138	157	135		
5	144	145	132	114	113	126	126	161	177		
6	156	124	87	111	121	130	104	198	38		
7	154	123	102	115	148	124	120	188	138		
8	162	125	87	169	112	125	141	185	72		
9	144	134	118	137	40	126	135	196	83		
10	143	136	116	109	112	128	177	223	186		
11	161	126	114	109	104	131	38	152	131		
12	167	123	116	158	133	119	138	154	126		

Şekil 3. 9 : EğitimVeri Seti Matlab




Şekil 3. 10 : Verilerin elde Ediliş Şeması

```

1
2 % train için değer alıyoruz
3 srcFiles = dir('D:\ORTOFOTO\newdata\traindata\bina\geo\*.tif');
4
5 for i = 1 : length(srcFiles)
6     filename = strcat('D:\ORTOFOTO\newdata\traindata\bina\geo\',srcFiles(i).name);
7     I = imread(filename);
8
9     [cR,rR,pR]=impixel(I(:, :,1));
10    x=[cR-2,cR-1,cR,cR+1,cR+2,cR-2,cR-1,cR,cR+1,cR+2,cR-2,cR-1,cR,cR+1,cR+2,cR-2,cR-1,cR,cR+1,cR+2,cR-2,cR-1,cR,cR+1,cR+2];
11    y=[rR-2,rR-2,rR-2,rR-2,rR-2,rR-2,rR-1,rR-1,rR-1,rR-1,rR-1,rR,rR,rR,rR,rR,rR,rR+1,rR+1,rR+1,rR+1,rR+1,rR+2,rR+2,rR+2,rR+2];
12    pixels = impixel(I,x,y);
13    mydataR(i)=pixels(:,1);
14    mydataG(i)=pixels(:,2);
15    mydataB(i)=pixels(:,3);
16
17 end

```

Şekil 3. 11 : Matlab Pixel Seçim



Şekil 3. 12 : Seçilen Pixele Göre Komşu Pixellerden Matris Oluşumu

Bu eğitim verileri, Şekil 3.10’de görüldüğü gibi her bir R, G, B kanalından, pixel bazında 5×5 lik matrisler halinde alınarak vektörler oluşturulmuş ve vektörel olarak hazırlanmıştır [30] . Tüm vektörler birleştirilerek Şekil 3.9’de görüldüğü gibi matris haline getirilmiştir. 5×5 ‘lik matrisler ise rastgele değil, Şekil 3.11 deki gibi komşuluk ilişkisine göre belirlenmiştir. Matlab programında fare ile tıkladığımız bölge merkez alınarak oluşturulmuştur Şekil 3.12. Eğitim verilerimiz ve test verilerimiz, 0-1 aralığına normalize edilmiştir.

Tablo 3. 1 : Eğitim, Test Alanları ve Piksel Sayıları


Sınıflar	Eğitim Noktası Sayı	Eğitim Alanı Sayı	Test Noktası Sayı	Test Alanı Sayı
Göl	60	1500	20	500
Bina	60	1500	20	500
Tarım alanı	60	1500	20	500
Toplam	180	4500	60	1500

Tablo 3.1 de görüldüğü üzere sınıflandırma yapılacak alanlar; göl, bina, tarım alanı'dır. Eğitim setinde her bir sınıftan 60 tane olmak üzere toplamda 180 tane alan seçilmiştir. Piksel bazında ise her bir alandan 25 piksel olmak üzere $60 \times 25 = 1500$ piksel seçilmiş olup toplamda 4500 piksel'dir. Test setinde ise her bir sınıftan 20 tane olmak üzere toplamda 60 tane alan seçilmiştir. Test piksel setimiz ise herbirisinden 500 tane olup toplamda 1500 piksel'dir.

3.2. Yapay Sinir Ağları Dizayn

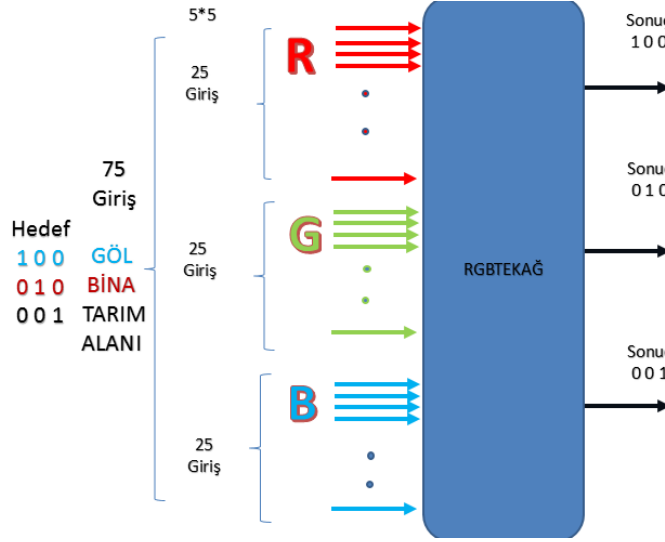
Bu tez çalışmasında farklı yapay sinir ağlarının ve ağ parametrelerinin sınıflandırma üzerindeki etkisi incelenmiştir. Ayrıca veri setinin piksel tabanlı farklı organizasyonu ve piksellerde elde edilen ortalama değer ve standart sapma gibi özniteliklerin performans üzerindeki etkileri incelenmiştir.

3.2.1. RGBTEKAĞ Yapay Sinir Ağı




Şekil 3. 13 : RGBTEKAĞ Yetmişbeş Girişli Tek Çıkışlı Yapay Sinir Ağı

Şekil 3.13'de RGBTEKAĞ adı verilen bir sinir ağ yapısı kullanılmıştır. Bu sinir ağ yapısında tek bir YSA sınıflandırıcının sınıflandırma yapması beklenmektedir. Dolayısı ile, tüm veri setlerinin giriş olarak tek bir yapay sinir ağına girmesi ve de sınıflardan birinin tek bir çıkış olarak elde edilmesi hedeflenmiştir. Çıkış katmanında her bir sınıf için bir etiken kullanılmıştır. Bu ağda göl, bina ve tarım alanı olmak üzere toplamda yetmişbeş tane giriş ve bir tane çıkış bulunmaktadır. Çıkış setimiz {1, 2, 3} şeklindedir [16].




Şekil 3. 14 : RGBTEKAĞ Yetmişbeş Girişli Üç Çıkışlı Yapay Sinir Ağı

İkinci yapı ise sadece çıkış nöron sayısının değiştirildiği bir sinir ağı modelidir. Burada çıkış her bir sınıfın bir tek nöron tarafından temsil edilmesine dayanmaktadır. Dolayısı ile Şekil 3. 14'de RGBTEKAĞ'da göl, bina ve tarım alanı olmak üzere toplamda yetmişbeş tane giriş ve üç tane çıkış bulunmaktadır. Dolayısı ile çıkış kodlaması her bir sınıf için {1 0 0, 0 1 0, 0 0 1} şeklindedir.



Şekil 3. 15 : RGBTEKAĞ Üç Girişli Tek Çıkışlı Yapay Sinir Ağı

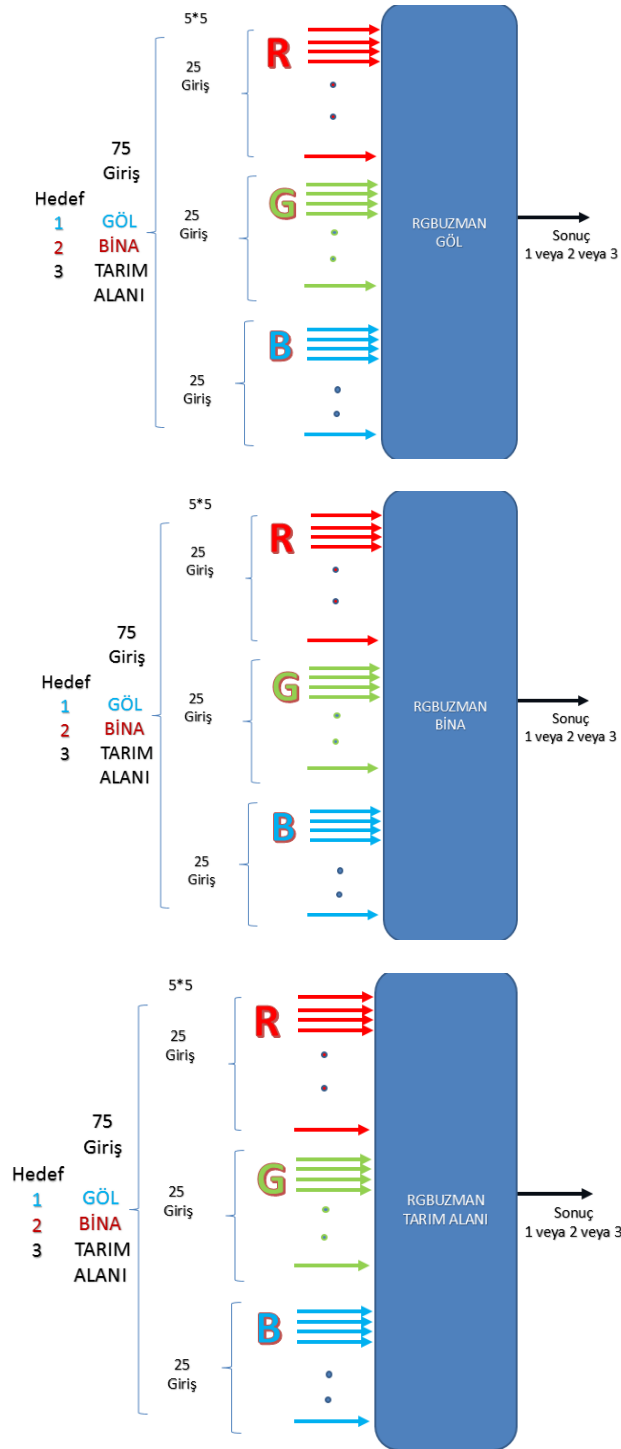
Şekil 3.15 deki ağda giriş veri seti, 25 pikselin ortalaması alınarak oluşturulmuştur, dolayısı ile her bir R,G,B kanalı için sadece bir ortalama değer olmak üzere toplamda üç ortalama değeri giriş olarak vermekteyiz. Bir tane çıkış bulunmaktadır. Çıkış setimiz {1, 2, 3} şeklindedir. Amacımız her bir kanalın ortalamasını alarak giriş setimizi azaltıp, kanal değerlerimize bir nitelik kazandırarak sonuca ulaşmaktır.



Şekil 3. 16 : RGBTEKAĞ Altı Girişli Tek Çıkışlı Yapay Sinir Ağı

Şekil 3.16 daki sinir ağ yapısında, giriş veri seti olarak, 25 pikselin hem ortalaması hemde varyansı alınmış olup, her bir R,G,B kanalı için sadece iki değer olmak üzere toplamda altı giriş vermekteyiz. Bir tane çıkış bulunmaktadır. Çıkış setimiz {1, 2, 3} şeklindedir.

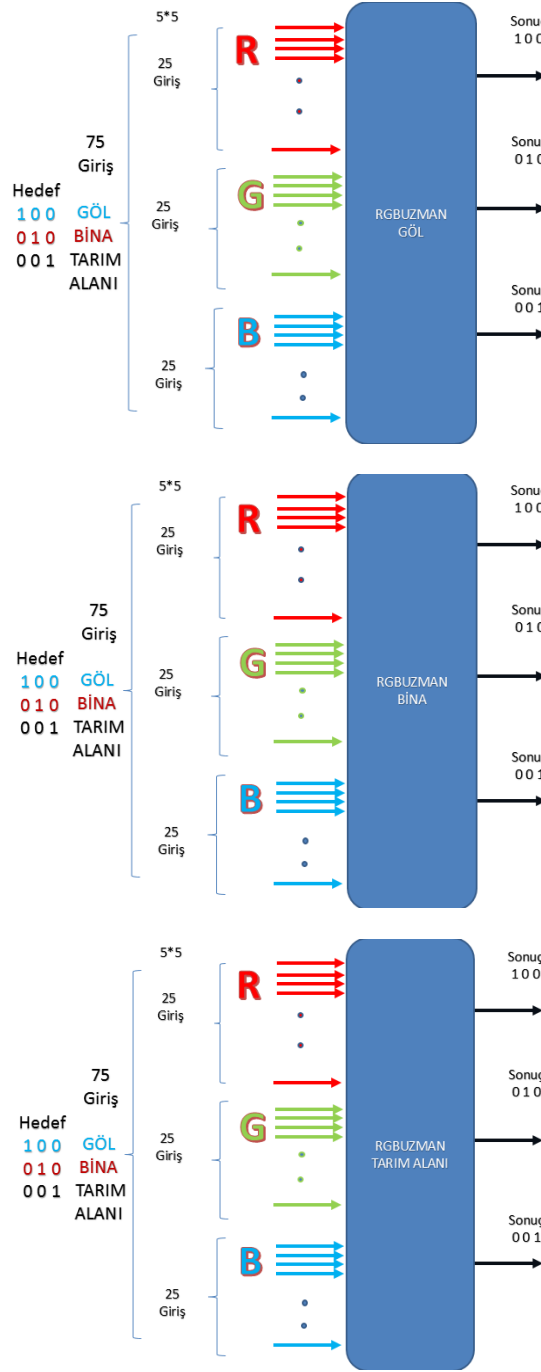
3.2.2. RGBUZMAN Yapay Sinir Ağı



Şekil 3. 17 : RGBUZMAN (Her Bir Ağ) Yetmişbeş Girişli Tek Çıkışlı Yapay Sinir Ağı

RGBUZMAN adını verdiğimiz ağda ise, tüm veri setlerinin hepsinin ayrı ayrı göl uzmanı, bina uzmanı, tarım uzmanı gibi uzman ağlara giriş olarak verilmesi ve sonucunda her bir uzman ağdan tek çıkış çıkması ile sonuca ulaşılmış olunur. Şekil 3. 17’de görüldüğü gibi her bir ağa

yetmişbeş tane giriş olmak üzere toplamda ikiyüzyirmibeş tane giriş vardır ve her birisinden çıkan bir tane çıkış bulunmaktadır.



Şekil 3. 18 : RGBUZMAN (Her Bir Ağ) Yetmişbeş Girişli Üç Çıkışlı Yapay Sinir Ağı

Şekil 3.18’da görüldüğü gibi her bir ağda yetmişbeş tane giriş olmak üzere toplamda ikiyüzyirmibeş tane giriş vardır ve çıkış kodlaması { 1 0 0, 0 1 0, 0 0 1 } olmak üzere her birisinde üç tane çıkış bulunmaktadır.

3.3. Yapay Sinir Ağlarında Kullanılan Parametreler

İleri beslemeli geri yayımlı yapay sinir ağı kullanılmıştır. Bunu için matlab daki fonksiyon *newff* fonksiyonudur. Yapay sinir ağlarında kullanılan aktivasyon fonksiyonu ise logaritmik sigmoid fonksiyonu olan *logsig* ve *purelin* fonksiyonlarıdır. Algoritma olarak ise *trainlm* (Levenberg-Marquardt) algoritması kullanılmıştır Çünkü diğer algoritmalara göre daha hızlı ve performanslıdır.

```
netaRGB = newff (allRGB, targetaRGB, 10 , {'logsig','purelin'}, 'trainlm');
```

Öğrenme Oranı:

Ağırlıkların değişim miktarı öğrenme katsayısı ile ilgilidir.

```
netaRGB.trainParam.lr = 0.01; % öğrenme hızı
```

Momentum:

Önceki iterasyonda meydana gelen değişimin belli bir miktarının sonraki miktara eklenmesidir. Yerele bağlı kalmaksızın sıçramalarla ağı hızlanmasını sağlar. Sıfır ile bir arasında olması hızı olumlu etkiler [17].

```
netaRGB.trainParam.mc = 0.5;
```

yapılan çalışmalara bakılarak 0.01 ve 0.08, 0.5 denenmiş ama 0.5 daha iyi sonuç verdiği gözlemlenmiştir.

Katman Sayısı:

10 tane ara katman kullanılmıştır; ara katmanlardaki eleman sayısının, verideki bant sayısının iki katından fazla olması benimsenen verilere göre ele alınmıştır. Ayrıca ara katman nöron sayıları 10, 20, 30 nöron olması durumu, denenmiş sonuçlara göre 10 nöronlu ara katmanın daha iyi sonuç verdiği görülmüştür.



Şekil 3. 19 : Kullanılan Ağ Yapısındaki Ara Katmanlar ve Fonksiyonlar

Şekil 3.19 deki yetmişbeş girişli verimizdeki veriler katsayılar ile çarpılıp sabit ile toplanmakta ve 10 nöronlu *logsig* fonksiyonunun birinci nöronuna sokulmaktadır, burdan çıkan sonuçlar ise ağırlıkla çarpıldıktan sonra katsayı ile toplanmakta ve *purelin* fonksiyonundan geçmektedir. Bu sadece tek bir döngüdür. Bu şekilde döngü sayısı da matlabdaki *epochs* ile belirlenmektedir.

`netaRGB.trainParam.show = 30;` Ağın ilerleyişindeki; eğitimin döngü aralıklarını belirler

`netaRGB.trainParam.epochs = 15000;` Eğitimdeki döngü sayısı

`netaRGB.trainParam.goal = 0.01;` Hata kareleri toplamı burdaki değer olduğunda döngünün sonlanmasını sağlar.

Train ise matlabda bu eğitimin yapılmasını sağlayan fonksiyondur.

```
[netaRGB]=train(netaRGB,allRGB,targetaRGB);
```

`allRGB` burda giriş verimiz, `targetaRGB` ise belirlediğimiz hedeftir.

```
testa =sim(netaRGB,testinputRGB);
```

Sim fonksiyonu ağımızın, verilen test giriş seti (`testinputRGB`) ile test edebilmesini sağlamaktadır.

BÖLÜM 4

SONUÇ

4. Sınıflandırmadan Elde Sonuçlar

Eğitim seti Matlab ile yazılan program tarafından eğitilmiş ve yine Matlab ile yazılan program tarafından test setinin simule edilmesi ile sonuçlar elde edilmiştir.

Tablo 4. 1 : Test İşlemi Sonuçları

Sınıflar/AĞ	RGBTEKAĞ YETMİŞBEŞ GİRİŞ TEK ÇIKIŞ (75-10-1)	RGBUZMAN YETMİŞBEŞ GİRİŞ TEK ÇIKIŞ (75-10-1)	RGBTEKAĞ YETMİŞBEŞ GİRİŞ ÜÇ ÇIKIŞ (75-10-3)	RGBUZMAN YETMİŞBEŞ GİRİŞ ÜÇ ÇIKIŞ (75-10-3)
Göl	%100	%100	%100	%100
Bina	%95	%95	%100	%95
Tarım alanı	%80	%55	%85	%75

Tablo 4.1’de görüldüğü üzere RGBTEKAĞ tek çıkışlı veya üç çıkışlı ağın performans açısından diğerlerinden çok daha iyi olduğu gözlemlenmiştir. Üç çıkışlı her bir ağın ise, tek çıkışlı ağa göre daha iyi sonuç verdiği ortaya çıkmıştır.

Tablo 4.2’ de RGBTEKAĞ da girişlerin ortalama değerlerinin alınmasıyla Üç Giriş Tek Çıkışın olduğu ağdaki performansın daha yüksek olduğu görülmektedir ama girişlerin hem ortalama hem de varyasyonunun alınarak altı giriş tek çıkış yapılan ağda performansın daha düşük olduğu görülmüştür.

Tablo 4. 2 : Test İşlemi Sonuçları

Sınıflar/AĞ	RGBTEKAĞ ÜÇ GİRİŞ TEK ÇIKIŞ (3-10-1)	RGBUZMAN ALTI GİRİŞ TEK ÇIKIŞ (6-10-1)
Göl	%100	%65
Bina	%95	%55
Tarım alanı	%85	%35

4.1. Doğruluk Analizi

Yukarıda yapılan denemelerden elde edilen sonuçların analiz edilmesi için literatürde kullanılan farklı analiz yöntemleri oluşturulmuştur. Bu yöntemler aşağıda sıralanmıştır.

Tablo 4. 3 : Hata Matrisi

Sınıflar	1	...	n	Kullanıcı Doğruluğu
1	X_{11}	...	X_{1n}	$\frac{X_{11}}{\sum_{j=1}^n X_{1j}} \times 100$
...
n	X_{n1}	...	X_{nn}	$\frac{X_{nn}}{\sum_{j=1}^n X_{nj}} \times 100$
Üretici Doğruluğu	$\frac{X_{11}}{\sum_{j=1}^n X_{i1}} \times 100$...	$\frac{X_{nn}}{\sum_{j=1}^n X_{n1}} \times 100$	Toplam Doğruluk $\frac{\sum_1^n X_{nn}}{\sum_{i=1}^n \sum_{j=1}^n X_{ij}} \times 100$

Hata Matrisi:

Hata matrisi, uzaktan algılamış görüntülerin sınıflandırmasında; doğruluk analizlerinde kullanılmaktadır. Hata matrisleri sınıflandırmada kullanılan hedef veriler ile sınıflandırma sonuçları arasındaki ilişkiyi karşılaştırır.

Kullanıcı Doğruluğu: Doğruluk hesaplanırken satırların dikkate alınmasıdır.

$$\frac{X_{nn}}{\sum_{j=1}^n X_{1j}} \times 100 \quad (4.1)$$

X_{nn} köşegen üzerinde bulunan değeri ifade etmektedir. $\sum_{j=1}^n X_{1j}$ ise satırda bulunan değerlerin toplamıdır.

Üretici Doğruluğu: Doğruluk hesaplanırken sütunların dikkate alınmasıdır.

$$\frac{X_{nn}}{\sum_{i=1}^n X_{i1}} \times 100 \quad (4.2)$$

X_{nn} köşegen üzerinde bulunan değeri ifade etmektedir. $\sum_{i=1}^n X_{i1}$ ise sütunda bulunan değerlerin toplamıdır.

Toplam Doğruluk: Toplamdaki piksel sayısının köşegende bulunan toplam piksel sayısına bölümününmesidir.

$$\frac{\sum_1^n X_{nn}}{\sum_{i=1}^n \sum_{j=1}^n X_{ij}} \times 100 \quad (4.3)$$

$\sum_1^n X_{nn}$ köşegen de bulunan değerlerin toplamı iken $\sum_{i=1}^n \sum_{j=1}^n X_{ij}$ tüm matris de bulunan değerlerin toplamıdır.

Kappa Değeri: Gözlenen uyumluluk oranı ile beklenen uyumluluk arsındaki farkı göstermek için kullanılır. Yani Hata Matrisi sonuçlarına erişimin şans mı yoksa gerçek bir uyumluluk mu olduğu sonuca varılır.

$$K = \frac{P_0 - P_e}{1 - P_e} \quad (4.4)$$

P_0 = Gözlenen uyumluluk oranı P_e = Beklenen uyumluluk oranı

$$K = \frac{\sum_1^n X_{nn} - \sum (\sum_{j=1}^n X_{ij} \sum_{j=1}^n X_{ji})}{1 - (\sum_{j=1}^n X_{ij} \sum_{j=1}^n X_{ji})}$$

Tablo 4. 4 : Kappa İstatiksel Değer Yorumları

K	Yorum
< 0	Hiç Uyuşma Olmaması
0.0 - 0.20	Önemsiz Uyuşma Olması
0.21 – 0.40	Orta Derece Uyuşma Olması
0.41 – 0.60	Ekseriyetle Uyuşma Olması
0.61 – 0.80	Önemli Derecede Uyuşma Olması
0.81 – 1.00	Neredeyse Mükemmel Uyuşma Olması

Kappa değerinin sonuç değer aralıklarının yorumlanması ise Tablo 4.4’de görülmektedir.

4.2. Yapılan Analizlerin Sonuçları

Tablo 4. 5 : RGBTEKAĞ Tek Çıkışlı Hata Matrisi (75-10-1)

Sınıflar	Göl	Bina	Tarım Alanı	Kullanıcı Doğruluğu
Göl	20	0	0	%100
Bina	0	19	4	%82.6
Tarım alanı	0	1	16	%94.1
Üretici Doğruluğu	%100	%95	%80	Toplam Doğruluk = %91.6

$$K = \frac{0.95 - (0.04 + 0.046 + 0.034)}{1 - (0.04 + 0.042 + 0.034)} = 88$$

Tablo 4. 6 : RGBUZMAN TEK Çıkışlı Hata Matrisi (75-10-1)

Sınıflar	Göl	Bina	Tarım Alanı	Kullanıcı Doğruluğu
Göl	20	0	2	%90
Bina	0	19	7	%73
Tarım alanı	0	1	11	%91.6
Üretici Doğruluğu	%100	%95	%55	Toplam Doğruluk = %83,3

$$K = \frac{0.83-0.12}{1-0.12} = 83.06$$

Tablo 4. 7 : RGBTEKAĞ Üç Çıkışlı Hata Matrisi (75-10-3)

Sınıflar	Göl	Bina	Tarım Alanı	Kullanıcı Doğruluğu
Göl	20	0	0	%100
Bina	0	20	3	%87
Tarım alanı	0	0	17	%100
Üretici Doğruluğu	%100	%100	%85	Toplam Doğruluk= %95

$$K = \frac{0.95-0.12}{1-0.12} = 94.3$$

Tablo 4. 8 : RGBUZMAN Üç Çıkışlı Hata Matrisi (75-10-3)

Sınıflar	Göl	Bina	Tarım Alanı	Kullanıcı Doğruluğu
Göl	20	0	1	%95.2
Bina	0	19	4	%82.6
Tarım alanı	0	1	15	%93,7
Üretici Doğruluğu	%100	%95	%75	Toplam Doğruluk = % 90

$$K = \frac{0.90-0.12}{1-0.12} = 88.6$$

Tablo 4. 9 : RGBTEKAĞ Üç Girişli Tek Çıkışlı Hata Matrisi (3-10-1)

Sınıflar	Göl	Bina	Tarım Alanı	Kullanıcı Doğruluğu
Göl	20	0	0	%95.2
Bina	0	19	3	%86.3
Tarım alanı	0	1	17	%94.4
Üretici Doğruluğu	%100	%95	%85	Toplam Doğruluk = % 93.3

$$K = \frac{0.933-0.122}{1-0.122} = 92.3$$

Kappa değerlerinin hepsi 0.81 ve üzeri olduğu görülmektedir. Sonuç mükemmel yakındır.

Yapılan Doğruluk analizlerinde en iyi sonuçları Tablo 4.7’de ve Tablo 4.9’de bulunan doğruluk analizinden aldık. Buda demek oluyor ki tek ağlar kullanılan uzman ağlara göre daha yüksek bir performans gösteriyor. Ayrıca giriş sayısının yüksek olması da performansı olumlu yönde etkiliyor.

4.3. Hava Fotoğraflarının Sınıflandırılması İle Elde Edilen Sonuçlar

Matlab kullanılarak yapılan yazılımda hava fotoğrafı 5×5 matrisler halinde 5 pixel kaydırılarak elde edilmiştir.




Şekil 4. 1 : Konya Beyşehir İlçesine Ait Test İçin Seçilen Görüntüler


Yukarıdaki görüntüler Konya Beyşehir ilçesine ait olup test için kullanılmıştır.

■ Tarım Alanı ■ Göl ■ Bina ■ Atanmamış

Sınıflandırılan görüntülerde kırmızı tarım alanını, mavi gölü, yeşil ise binayı temsil etmektedir.




Şekil 4. 2 : RGBUZMAN Tek çıkışlı Sınıflandırma




Şekil 4. 3 : RGBUZMAN Tek çıkışlı Sınıflandırma Sonuç

Şekil 4.2’ de görülen sınıflandırmada uzman olan ağın her birisinden çıkan sonuçlardır, Şekil 4.3’ de görülmekte olan ise ağların sonuçlarından çıkan en büyük değerin sonuç olarak alınmasıyla ortaya çıkan sınıflandırmadır.




Şekil 4. 4 : RGBTEKAG Tek Çıkışlı Sınıflandırma




Şekil 4. 5 : RGBTEKAG Üç Çıkışlı Sınıflandırma

Şekil 4.4’ de 75-10-1 olan ağ yapısının ve Şekil 4.5’ de 75-10-1 olan ağ yapısının sınıflandırma sonuçları görülmektedir. Bunlar yapılan doğruluk analizlerinde sonuç veren en iki ağdır.




Şekil 4. 6 : RGBUZMAN Üç Çıkışlı Sınıflandırma



Şekil 4. 7 : RGBUZMAN Üç Çıkışlı Sınıflandırma Sonuç

Şekil 4.6' da uzman ağların her birisinden çıkan sonuçlar yer almaktadır. Şekil 4.7' de ise uzman ağlardan çıkan sonuçlardan en büyük olan değer alınmıştır. Şekil 4.2 ve Şekil 4.3'e oranla sınıflandırma doğruluğu çok daha yüksektir.




Şekil 4. 8 : RGBTEKAĞ Üç Girişli Tek Çıkışlı Sınıflandırma

Şekil 4.8'de ortalama değerler alınarak yapılan sınıflandırma sonucu görülmektedir. Sınıflandırmaya bakıldığında neredeyse hiç bir siyah alanın görülmemektedir.

Test sonuçlarına ve hata matrislerine bakılacak olursa, bina ve tarım alanı başarı oranının daha düşük olduğu görülmüştür. Bunun sebebi ise histogram değerlerinin birbirine yakın olmasından kaynaklanmaktadır.

Mevlana Kalkınma Ajansı yayınladığı raporda Beyşehir ilçesine ait toprak çeşitliliği aşağıdaki şekilde belirtilmiştir;

Kireçsiz kahverengi topraklar, kestane rengi topraklar, kırmızı akdeniz toprakları, kırmızı kahverengi akdeniz toprakları, sazlık ve bataklık araziler, sahil kumulları bulunmaktadır [18].



Şekil 4. 9 :Beyşehir İlçesi Toprak Yoğunlukları [19]

Yapılan başka bir araştırmada;

Kırmızımsı Kahverengi (KK), Kahverengi ve Koyu Kahverengi 3 (KAHKOY), Kahverengi ve Koyu Kahverengi 1-2 (KHKYK) türlerinin yüzdesi gösterilmiştir [19].

Eğitim ve test işleminde bina ve tarım alanı olarak sınıflandıracağımız kısmın, sınıflandırma yüzdesinin düşük çıkmasının sebepleri arasında, toprak tipinde kırmızı toprağın yoğun olarak görülmesi, tarım ve bina olarak seçtiğimiz eğitim ve test verisinde de kırmızı rengin yoğun olmasından kaynaklanmaktadır.

4.4. SONUÇ

Bu çalışmada uzaktan algılanmış görüntülerin yapay sinir ağları ile sınıflandırılması ele alınmıştır. Yapılan çalışmalar ile farklı ağ yapıları ve ağ parametrelerinin sınıflandırma performansı üzerindeki etkileri incelenmiştir. Ayrıca veri setinin oluşturulmasında kullanılan farklı özniteliklerin sınıflandırma performansına etkisi de ele alınmıştır

Uzaktan algılanmış görüntülerin sınıflandırılmasında işlem yapılan bant sayısı, önemlidir. Çünkü işleme tabi olan her bant sınıfların birbirinden ayırt edilebilmesini sağlayacak yeni bir bilgi kaynağıdır. Bu tezde kullanılan bant sayısı ise üç tane olup sadece R, G, B'dir.

Toplamda 4500 eğitim noktası eğitilmiş olup 1500 eğitim noktası test edilmiştir. Sınıflarımız; Göl, bina ve toprak 'tır. Test verilerinden elde edilen sonuçlara göre test edilen ağlardan en başarılısı, yapılan doğruluk analizlerine göre %95 ile RGBTEKAĞ üç çıkışlı (75-10-3) yapay sinir ağıdır. RGBTEKAĞ üç girişli tek çıkışlı (3-10-1) yapay sinir ağının sonucu ise %93.3'dür ve en iyi ikinci sonuç olduğu gözlenmiştir. RGBTEKAĞ tek çıkışlı yapay sinir ağı (75-10-1) sınıflandırma sonucu %91.6 ve RGBUZMAN üç çıkışlı sınıflandırma (75-10-3) sonucu ise %90'dır. RGBUZMAN tek Çıkışlı sınıflandırma (75-10-3) sonucu ise %83.3 dür.

Literatürde yapılan çalışmalarda ise 7 bantlı bir veri seti sonucunda %87 başarı sağlanırken [28], Landsat çok bantlı bir uydu görüntüsünde kullanılan çok katmanlı algılayıcı ile yapılan başka bir çalışmada ise başarı oranı %88.13'dür. 6-15-8 ağ yapısı kullanılmıştır [29].

Onbeş bantlı uydu görüntüsünde ise çok katmanlı algılayıcı ile yapılmış test sonuçlarında başarı oranı %89.6'dır. 15-8-5 ağ yapısı kullanılmıştır [30].

Yapılan bir başka çalışmada ise ortalama, standart sapma, çarpıklık katsayısı, basıklık katsayısı gibi değerleri kullanarak çok katmanlı yapay sinir ağı girişlerini belirlenmiş ama sonuç %85 olarak çıkmıştır. 18-6-6 ağ yapısı kullanılmıştır [31].

Literatürde yapılan çalışmalar ile bu çalışmada yapılan test sonuçları kıyaslanması oldukça zor olmasına rağmen elde edilen sonuçlarda başarı gözlemlenmiştir. Bunun olumlu sebebi ise doğru giriş ve çıkışların belirlenmesi ile yapay sinir ağlarında kullanılan parametrelerin doğru seçilmesinden kaynaklanmaktadır. RGBUZMAN ağlarında daha çok başarı beklenmesine rağmen sonuçların beklenene oranla biraz düşük olduğu görülmüştür. Fakat bu uzman ağlar tek bir sınıflandırma için daha kesin sonuç vermektedir örneğin yıllara göre yeşil alan miktarının incelenmesi.

KAYNAKLAR

- [1] Örmeci, C., 1987. Uzaktan Algılama: Temel Esaslar ve Algılama Sistemleri. Cilt I, İstanbul Teknik üniversitesi Matbaası, İstanbul.
- [2] Kavzoğlu, T., Reis S., 2008. Performance Analysis of Maximum Likelihood and Artificial Neural Network Classifiers for Training Sets with Mixed Pixels. GIScience and Remote Sensing, 45(3), 330-342.
- [3] Schowengerdt, R.A. , 1997. Remote Sensing; Models and Methods for Image Processing. New York: Academic Press.
- [4] [www.acikders.org.tr/pluginfile.php/645/mod_resource/content/0/Ek Kaynaklar/siniflandirma.pdf](http://www.acikders.org.tr/pluginfile.php/645/mod_resource/content/0/Ek_Kaynaklar/siniflandirma.pdf)
- [5] www.yildiz.edu.tr/~bayram/sgi/saygi.htm
- [6] Çelik, H., 2006. İstanbul Sarıyer İlçesine Ait Uzaktan Algılama Uydu Verileri ile Mekânsal Veri Analizleri. Yüksek Lisans Tezi, Çanakkale 18 Mart Üniversitesi, Çanakkale.
- [7] Fausett, L., 1994. Fundamentals of neural networks:Arhitecture, Algorithms and Applications, Prentice Hall.
- [8] Karabük Üniversitesi, Mühendislik Fakültesi, İleri algoritma analizi-5 yapay sinir ağıları Ders Notu, www.ibrahimcayiroglu.com
- [9] http://www.dacs.dtic.mil/techs/neural/neural_ToC.html, 2006.
- [10] Özkan, C. , 2001. Uydu Görüntü Verilerinin Yapay Sinir Ağları ile Sınıflandırılması. Doktora tezi, İTÜ Fen Bilimleri Enstitüsü, İstanbul.
- [11] Kavzoğlu, T., 2001. An Investigation of The Design And Use of Feed-Forward Artificial Neural Networks In The Classification of Remotely Sensed Images, Phd Thesis, University of Nottingham, England.
- [12] geomatik.beun.edu.tr/marangoz/files/2013/03/JDF821Giris1.pdf
- [13] Kavzoglu, T. and Mather, P.M., 2003. The use of backpropagating artificial neural networks in land cover classification. International Journal of Remote Sensing, 23, 2919-2937.
- [14] Aria, E. H. , Amini, J., Saradjian, M.R., 2003. Back Propagation Neural Network for Classification of IRS-1D Satellite Images, Department of geomantics, Faculty of Engineering, Tehran University, Iran.
- [15] Boggess, J. E. and Drawer P. O. Identification of Roads in Satellite Imagery

- Using Artificial Neural Networks: A Contextual Approach, U. S. Army Corps of Engineers Waterways Experiment Station Geotechnical Laboratory Mobility Systems Division, Mississippi State University.
- [16] Liu, J., Shao, G., Zhu, H. and Liu, S., 2004. A neural network approach for information extraction from remotely sensed data. Geospatial Information Research: Bridging the Pacific and Atlantic University of Gävle, Sweden, 7-9 June 2004.
- [17] Çetin, M., Uğur, A. ve Bayzan, Ş. 2006. “İleri Beslemeli Yapay Sinir Ağlarında Backpropagation (Geriye Yayılım) Algoritmasının Sezgisel Yaklaşımı”, Akademik Bilişim Kongresi, Pamukkale Üniversitesi, Denizli, Şubat 2006.
- [18] Mevlana kalkınma Ajansı, 2011. Beyşehir İlçesi Raporu.
- [19] Özkan K. , Mert A. , Gülsoy S. , 2007. Beyşehir gölü havzası topraklarının bazı özellikleri ile toprak rengi ve strüktürü arasındaki ilişkiler. Süleyman Demirel Üniversitesi Orman Fakültesi Dergisi. Seri: A, Sayı: 2, Yıl: 2007, ISSN: 1302-7085, Sayfa: 9-22.
- [20] Kavzoğlu T., Çölkesen İ. Karar Ağaçları İle Uydu Görüntülerinin Sınıflandırılması: Kocaeli Örneği, Gebze Yüksek Teknoloji Enstitüsü, Jeodezi ve Fotogrametri Mühendisliği Bölümü, Gebze, Kocaeli. Harita Teknolojileri Elektronik Dergisi Cilt: 2, No: 1, 2010 (36-45).
- [21] Hepner, G. E, Logan, T, Ritter, N. 1990. Artificial neural network classification using a minimal training set: comparison to conventional supervised classification. Photogrammetry engineering and Remote Sensing, 56, 469-473.
- [22] Dreyer P. , 1993. Classification of Land cover using optimised neural nets on spot data, photogrammetric engineering and remote sending, 59, 617-621.
- [23] Omatu S., Yosida T. 1991. Category Classification Using Neural Networks. Soft Computing in Industrial Electronics Volume 101 of the series Studies in Fuzziness and Soft Computing, 324-345.
- [24] Kanellopoulos, I., Warfis, A., Wilkinson, G., Megier, J., 1992. Land Cover discrimination in SPOT HRV imagery using an artificial neural network, International Journal of remote sensing a 20 class experiment. International Journal of Remote Sensing, 13, 917- 924.
- [25] Kansu, O., 2006. Uzaktan Algılamada Görüntü Sınıflandırma Yöntemleri Analizi, Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü, Trabzon.
- [26] Çetin, M., Kavzoğlu, T. and Musaoğlu, N., 2004. Classification of Multi-Spectral, Multi-Temporal and Multi-Sensor Images Using Principle Component Analysis and Artificial

Neural Networks: Beykoz Case, XXth Congress of the International Society for Photogrammetry and Remote Sensing (ISPRS), 12-25 July 2004, Istanbul, Turkey

- [27] Chitwong, S., Witthayapradit, S., Intajag, S., Cheevasuvit, F.. Multispectral Image Classification Using Back-Propagation Neural Network in pca domain. WSEAS transactions on information science and applications Issue 4, Volume 1, October 2004 ISSN 1790-0832.
- [28] Çetinkaya, B., Toz, G., 2007. Coğrafi veri seçim işlemi sonuçlarının değerlendirilmesinde hata matrisinin kullanımı. İTÜ Fen Bilimleri Enstitüsü, Jeodezi ve Fotogrametri Mühendisliği Programı, İstanbul. itüdergisi mühendislik Cilt:6, Sayı:5-6, 59-68.
- [29] Yuan H., Cynthia F. , Wiele V. D., and Khorram S., 2009. An Automated Artificial Neural Network System for Land Use/Land Cover Classification from Landsat TM Imagery, North Carolina State University, Raleigh, North Carolina, USA. Remote Sens. 2009, 1, 243-265.
- [30] Çetin, M., Kavzoglu, T., Musaoglu, N.,2004. Remote Sensing Image Classification of the Improved BP NN, Istanbul Technical University, Civil Engineering Faculty, Istanbul. Proceedings of 20th Congress of the International Society of Photogrammetry and Remote Sensing, Istanbul, 12-23 July 2004.
- [31] Roli, F., Serpico, S.B., Bruzzone, L., and Vernazza, G., 1996. Classification of multispectral remote-sensing images by neural networks, Cagliari, Genova Italy. European Signal Processing Conference, 8th.

