



**T.C.
AKSARAY ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

HARİTA MÜHENDİSLİĞİ ANABİLİM DALI

**YAPAY ARI KOLONİ ALGORİTMASININ TARIM ALANLARININ
SINIFLANDIRILMASINDA KULLANILABİLİRLİĞİNİN
İRDELENMESİ**

YÜKSEK LİSANS TEZİ

Ahmet Tarık TORUN

DANIŞMAN


Doç. Dr. Selçuk REİS

AKSARAY, 2015

AKSARAY ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ
ONAY BELGESİ

Aksaray Üniversitesi, Fen Bilimleri Enstitüsü'nün 122306404 numaralı Yüksek Lisans öğrencisi, "Ahmet Tarık TORUN", ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı "YAPAY ARI KOLONİ ALGORİTMASININ TARIM ALANLARININ SINIFLANDIRILMASINDA KULLANILABİLİRLİĞİNİN İRDELENMESİ" başlıklı tezini, aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : Doç. Dr. Selçuk REİS
Aksaray Üniversitesi



Jüri Üyeleri : Prof. Dr. Coşkun ÖZKAN
Erciyes Üniversitesi



Jüri Üyeleri : Doç. Dr. Semih EKERCİN
Aksaray Üniversitesi



Teslim Tarihi: 25 Haziran 2015

Savunma Tarihi: 10 Temmuz 2015

ÖNSÖZ

Dünden bugüne uydu görüntülerinin sınıflandırılması işlemi, teknolojinin hızlı gelişimi ve uydu görüntülerinin kalitesinin artması ile daha da büyük önem kazanmıştır. Bununla birlikte son 20 yılda yaygın olarak kullanılmaya başlanan yapay zekâ uygulamaları da uzaktan algılamada sınıflandırma işleminde kullanılabilir olmuştur.

Bu çalışma, Aksaray Üniversitesi Fen Bilimleri Enstitüsü Harita Mühendisliği Anabilim Dalında yüksek lisans tezi olarak hazırlanmıştır. Çalışmada yapay zeka optimizasyon algoritmalarından biri olan Yapay Arı Koloni algoritmasının uzaktan algılamada görüntü sınıflandırma işleminde kullanılması irdelenmiştir. Bu amaçla WorldView-2 ve Quickbird uydu görüntüleri kullanılarak en çok benzerlik, yapay sinir ağları ve yapay zeka optimizasyon algoritmaları kullanılarak sınıflandırmalar yapılmıştır. Sınıflandırma sonuçları test verileri ile kontrol edilerek doğruluk analizleri yapılmıştır.

Bu tez çalışması, Aksaray Üniversitesi Bilimsel Araştırma Projeleri 2014-008 numaralı proje kapsamında gerçekleştirilmiştir.

Ahmet Tarık TORUN

Aksaray, Temmuz 2015

DOĞRULUK BEYANI

Yüksek lisans tezi olarak sunduğum bu çalışmayı, bilimsel etik, ahlak ve geleneklere aykırı düşecek bir yol ve yardıma başvurmaksızın yazdığımı, yararlandığım eserlerin kaynakçada gösterilenlerden oluştuğunu ve bu eserleri her kullanışmada alıntı yaparak yararlandığımı belirtir; bunu şerefimle doğrularım.

Enstitü tarafından belli bir zamana bağlı olmaksızın, tezimle ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçlara katlanacağımı bildiririm.

Ahmet Tarık TORUN

İmza

TEŞEKKÜR

En başta ve her şeyden önce beni bugünlere getiren ve eğitim hayatımın her alanında hiçbir fedakârlığı esirgemeyen, fedakâr annem Fatma TORUN ve muhterem babam Suat TORUN' a ve çok sevdiğim kız kardeşlerime en içten minnet duygularıyla teşekkürlerimi sunarım.

Lisans ve lisansüstü eğitimim boyunca bilgi ve deneyimleriyle bana her konuda yol gösteren ve her zaman destek olan danışman hocam Doç. Dr. Selçuk REİS' e ve tez çalışmam esnasında her zaman beni destekleyen Aksaray Üniversitesi Harita Mühendisliği Bölümü mesai arkadaşlarıma sonsuz teşekkürlerimi sunarım. Ayrıca tez çalışmam boyunca öğretileri ve önerileri ile bir yol gösterici görevi yapan Arş. Gör. Ahmet Emin KARKINLI (Erciyes Üniversitesi Harita Mühendisliği Bölümü)' ya teşekkürlerimi sunarım.

Bana hem arkadaş, hem en yakın dost olan, sevgi ve saygıyı beraber sunabilen nadide insan, sevgili EŞİM... Bu tez çalışmamda da her daim olduğu gibi bana desteğini esirgemediği için saygıdeğer eşim Çiğdem TORUN' a müteşekkirim.

İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	i
DOĞRULUK BEYANI.....	ii
TEŞEKKÜR	iii
İÇİNDEKİLER	iv
ÖZET.....	vi
ABSTRACT	vii
ŞEKİLLER DİZİNİ	viii
ÇİZELGELER DİZİNİ	ix
KISALTMALAR DİZİNİ	x
SİMGELER DİZİNİ	xi
1. GİRİŞ	1
2. UZAKTAN ALGILAMA VE TEMEL BİLEŞENLERİ	4
2.1 Uzaktan Algılamada Kullanılan Algılayıcı Sistemler.....	5
2.1.1 QuickBird uydu sistemi	5
2.1.2 WorldView uydu sistemi	6
2.2 Uzaktan Algılamanın Kullanım Alanları	8
2.3 Uzaktan Algılamada Görüntü İşleme Teknikleri	9
2.3.1 Ön işlem süreci.....	9
2.3.2 Görüntü zenginleştirme.....	10
2.3.3 Sınıflandırma.....	11
2.3.3.1 Klasik sınıflandırma teknikleri.....	12
2.3.3.2 Uzaktan algılamada yeni görüntü sınıflandırma yaklaşımları	14
3. YAPAY SİNİR AĞLARI.....	17
3.1 Yapay Sinir Ağlarının Çalışma Prensipleri	18
3.2 Yapılarına Göre Yapay Sinir Ağları	20
3.2.1 İleri beslemeli yapay sinir ağları	20
3.2.2 Geri beslemeli yapay sinir ağları	21
3.3 Öğrenme algoritmalarına göre yapay sinir ağları.....	21
3.3.1 Kontrollü öğrenme	21
3.3.2 Kontrolsüz öğrenme	21
3.3.3 Takviyeli öğrenme	22
3.4 Çok Katmanlı Perseptron	22
3.5 Yapay Sinir Ağları ile Uydu Görüntülerinin Sınıflandırılması.....	23
4. YAPAY ARI KOLONİ ALGORİTMASI (YAKA)	27
4.2 Arıların Yiyecek Arama Davranışları	27
4.3 Yapay Arı Koloni Algoritmasının İşleyişi	30
4.3.1 Yiyecek kaynaklarının üretilmesi	30
4.3.2 Görevli arıların yiyecek kaynağı bölgelerine gönderilmesi	31
4.3.3 Gözcü arıların olasılık değerlerini hesaplaması	32

4.3.4 Gözcü arıların yiyecek kaynağı bölgelerini seçmesi.....	32
4.3.5 Tükenen kaynağı bırakma ve yeni kaynaklar bulunması.....	32
4.4 YAKA'nın Temel Özellikleri ve Literatürde Kullanımı.....	32
4.5 YAKA ile Uydu Görüntülerinin Sınıflandırılması.....	34
5. ÇALIŞMA ALANI VE UYGULAMA	35
5.1 Çalışma Alanı Seçimi.....	35
5.2 Kullanılan Veri ve Yazılımlar	36
5.3 Genel Bilgiler	38
5.4 YAKA Kodlarının MATLAB Yazılımında Düzenlenmesi	38
5.5 Eğitim ve Test Alanlarının Belirlenmesi.....	39
5.6 Sınıflandırma İşlemleri.....	40
5.6.1 Kontrolsüz sınıflandırma işlemleri.....	40
5.6.1.1 ISODATA kontrolsüz sınıflandırma	40
5.6.1.2 YAKA ile kontrolsüz sınıflandırma	43
5.6.2 Kontrollü sınıflandırma işlemleri.....	46
5.6.2.1 En çok benzerlik algoritması ile sınıflandırma	46
5.6.2.2 YSA ile Sınıflandırma.....	50
5.6.2.3 YAKA ile kontrollü sınıflandırma	54
5.7 YAKA'nın EÇB ve YSA ile Karşılaştırılması.....	58
6. SONUÇ VE ÖNERİLER.....	60
7. KAYNAKLAR	62
ÖZGEÇMİŞ.....	68

ÖZET

YAPAY ARI KOLONİ ALGORİTMASININ TARIM ALANLARININ SINIFLANDIRILMASINDA KULLANILABİLİRLİĞİNİN İRDELENMESİ

Türkiye tarım alanları bakımından zengin bir ülke konumundadır. Bu nedenle tarım alanlarının kullanımı hakkında bilgi edinilmesi önem arz etmektedir. Uzaktan algılama ile görüntü sınıflandırma işlemleri uydu görüntülerinden bilgi çıkarımı konusunda büyük bir öneme sahiptir. Tarım alanlarının uydu görüntüleri üzerinden sınıflandırılması, bu alanlar hakkında bilgi edinme açısından çeşitli kolaylıklar sunmaktadır. Uydu görüntüleri üzerinden tarımsal nitelikteki alanları belirlemek ve ürün çeşitlerinin alansal dağılımı hakkında bilgi çıkarımı yapmak mümkündür. Bu amaçla uzaktan algılama görüntü sınıflandırma işlemlerinde birçok yöntem kullanılmaktadır. Bu yöntemler başlıca, en yakın mesafe, maksimum benzerlik, paralelkenar yöntemi vb. olarak sıralanabilir. Bu yöntemlere ek olarak son zamanlarda ortaya çıkan yapay zeka optimizasyon algoritmaları, klasik yöntemlere alternatif olma özelliği göstermektedir. Bu tez çalışmasında çok yüksek çözünürlüklü uydu görüntüleri yapay arı koloni algoritması (YAKA) kullanılarak sınıflandırılmıştır. Böylece YAKA'nın sınıflandırma doğruluklarının araştırılmasına yönelik irdellemeler gerçekleştirilmiştir. Araziden ve hava fotoğraflarından yararlanılarak gerekli olan yer kontrol noktaları ve eğitim verileri toplanmıştır. Çalışma alanı olarak, bitki örtüsü, arazi topoğrafyası ve tarım alanları göz önüne alınarak, Rize ili pilot bölge olarak seçilmiştir. Uygulama sonucunda Yapay Arı Koloni Algoritması ile elde edilen doğruluk değerleri yapay sinir ağları ve en çok benzerlik algoritması ile karşılaştırılarak değerlendirilmiş ve YAKA ile elde edilen doğruluk diğer sınıflandırma algoritmalarına nazaran daha iyi sonuçlar verdiği gözlemlenmiştir.

Anahtar Kelimeler: Yapay Arı Koloni Algoritması, Yapay Sinir Ağları, Görüntü Sınıflandırma, Uzaktan Algılama, En Çok Benzerlik, Quickbird, Worldview-2

ABSTRACT

INVESTIGATION OF CLASSIFICATION OF AGRICULTURAL AREAS BY USING THE ARTIFICIAL BEE COLONY ALGORITHM

Turkey is a rich country when it comes to agricultural areas. Therefore it is substantial to gain information about the usage of these areas. Image classification processes with remote sensing has a large share in the extraction of information from satellite images. Classification of agricultural areas from satellite images provides various conveniences in terms of gain information about these areas. It is possible to detect agricultural areas and extract information about which products are grown in which areas through the satellite images. Various methods are used in remote sensing for image classification process. These methods can be sorted as minimum distance, maximum likelihood and parallelepiped method etc. AI optimization algorithms that recently emerged shows the feature of being an alternative to conventional methods. In this thesis, very high resolution satellite images classified using artificial bee colony algorithm. Thus, performed explorations about investigations of classification accuracies of ABC. Necessary control points and training data were collected by using land and aerial images. Rize was chosen for the pilot region as a study area by taking into consideration the vegetation, land topography and agricultural areas. At the end of the application accuracy values that obtained by using the artificial bee colony algorithm were compared with the artificial neural network and maximum likelihood algorithm. It has shown that artificial bee colony algorithm give better accuracy rates than other methods.

Key Words: Artificial Bee Colony Algorithm, Artificial Neural Network, Image Classification, Remote Sensing, Maximum Likelihood, Quickbird, Worldview-2

ŞEKİLLER DİZİNİ

	<u>Sayfa</u>
Şekil 2.1: Elektromanyetik spektrum ve spektral aralıklar.....	5
Şekil 2.2: En çok benzerlik ile tanımlanan olasılık yoğunluk Fonksiyonları	13
Şekil 3.1: Biyolojik nöronun genel yapısı.	19
Şekil 3.2: Yapay nöronun genel yapısı ve bileşenleri.....	20
Şekil 3.3: Dört tabakalı ileri beslemeli çok katmanlı perseptron.....	22
Şekil 3.4: Logaritmik sigmoid fonksiyonu giriş-çıkış eğrisi (A), tanjant sigmoid fonksiyonu giriş -çıkış eğrisi (B).....	24
Şekil 4.1: Arılarda yiyecek arama döngüsü.....	29
Şekil 5.1: Rize ili haritası ve seçilen çalışma alanları.	36
Şekil 5.2: WorldView-2 uydu görüntüsü ve bant özellikleri.....	37
Şekil 5.3: QuickBird uydu görüntüsü ve bant özellikleri.	37
Şekil 5.4: Quickbird uydu görüntüsü ISODATA kontrolsüz sınıflandırma sonuç haritası.....	42
Şekil 5.5: Worldview-2 uydu görüntüsü ISODATA kontrolsüz sınıflandırma sonuç haritası.....	42
Şekil 5.6: Quickbird uydu görüntüsü YAKA kontrolsüz sınıflandırma sonuç haritası.....	44
Şekil 5.7: Worldview-2 uydu görüntüsü YAKA kontrolsüz sınıflandırma sonuç haritası.....	45
Şekil 5.8: Quickbird uydu görüntüsü EÇB yöntemi ile sınıflandırma sonuç haritası.....	48
Şekil 5.9: Worldview-2 uydu görüntüsü EÇB yöntemi ile sınıflandırma sonuç haritası.....	49
Şekil 5.10: Worldview-2 6 Bant+NDVI uydu görüntüsü EÇB yöntemi ile sınıflandırma sonuç haritası.	49
Şekil 5.11: Quickbird uydu görüntüsü YSA yöntemi ile sınıflandırma sonuç haritası.....	52
Şekil 5.12: Worldview-2 uydu görüntüsü YSA yöntemi ile sınıflandırma sonuç haritası.....	53
Şekil 5.13: Worldview-2 6 Bant+NDVI uydu görüntüsü YSA yöntemi ile sınıflandırma sonuç haritası.	53
Şekil 5.14: Quickbird uydu görüntüsü YAKA kontrollü sınıflandırma yöntemi ile sınıflandırma sonuç haritası.	56
Şekil 5.15: Worldview-2 uydu görüntüsü YAKA kontrollü sınıflandırma yöntemi ile sınıflandırma sonuç haritası.	56
Şekil 5.16: Worldview-2 6 Bant+NDVI uydu görüntüsü YAKA kontrollü sınıflandırma sonuç haritası.	57
Şekil 5.17: Sınıflandırma yöntemlerine ait genel doğruluk karşılaştırması.	58
Şekil 5.18: Sınıflandırma yöntemlerine ait kappa değerlerinin karşılaştırılması.	58
Şekil 5.19: Çay alanlarının üretici ve kullanıcı doğrulukları.....	59
Şekil 5.20: Ağaçlık alanların üretici ve kullanıcı doğrulukları.....	59

ÇİZELGELER DİZİNİ

Sayfa

Çizelge 2.1: Quickbird Uydusu Teknik Özellikleri	6
Çizelge 2.2: Worldview-2: Uydusu Teknik Özellikleri	7
Çizelge 2.3: .. Uzaktan algılamanın kullanıldığı bilim dalları ve çalışma alanları.....	8
Çizelge 3.1: Biyolojik sinir sistemi ve YSA benzerlikleri.	19
Çizelge 5.1: Quickbird ve Worldview-2 uydu verileri için arazi örtüsü sınıfları.	39
Çizelge 5.2: . ISODATA yöntemi ile sınıflandırma doğruluk değerleri.....	41
Çizelge 5.3: Worldview-2 uydu görüntüsü için ISODATA yöntemi ile sınıflandırma hata matrisi.	41
Çizelge 5.4: Quickbird uydu görüntüsü için ISODATA yöntemi ile sınıflandırma hata matrisi.	41
Çizelge 5.5: .. YAKA ile kontrolsüz sınıflandırma sonucu doğruluk değerleri.....	43
Çizelge 5.6: Worldview-2 uydu görüntüsü için YAKA ile kontrolsüz sınıflandırma hata matrisi.	44
Çizelge 5.7: Quickbird uydu görüntüsü için YAKA ile kontrolsüz sınıflandırma hata matrisi.....	44
Çizelge 5.8: En çok benzerlik algoritması ile sınıflandırma sonucu doğruluk değerleri.....	47
Çizelge 5.9: Worldview-2 uydu görüntüsü için EÇB algoritması ile sınıflandırma hata matrisi.	47
Çizelge 5.10: Quickbird uydu görüntüsü için EÇB algoritması ile sınıflandırma hata matrisi.....	47
Çizelge 5.11: Worldview-2 6 Bant+NDVI görüntüsü için EÇB algoritması ile sınıflandırma hata matrisi.....	48
Çizelge 5.12: YSA ile sınıflandırma sonucu doğruluk değerleri.....	51
Çizelge 5.13: Worldview-2 uydu görüntüsü için YSA sınıflandırma hata matrisi....	51
Çizelge 5.14: Quickbird uydu görüntüsü için YSA sınıflandırma hata matrisi.....	52
Çizelge 5.15: Worldview-2 6 Bant+NDVI görüntüsü için YSA sınıflandırma hata matrisi.....	52
Çizelge 5.16: YAKA ile kontrollü sınıflandırma sonucu doğruluk değerleri.	55
Çizelge 5.17: Worldview-2 uydu görüntüsü YAKA ile sınıflandırma hata matrisi ..	55
(ÜD: Üretici Doğruluğu-KD: Kullanıcı Doğruluğu).	55
Çizelge 5.18: Quickbird uydu görüntüsü YAKA ile sınıflandırma hata matrisi.	55
Çizelge 5.19: Worldview-2 6 Bant+NDVI görüntüsü için YAKA kontrollü sınıflandırma hata matrisi.....	55

KISALTMALAR DİZİNİ

AVHRR	Advanced Very High Resolution Radiometer
ÇKP	Çok katmanlı perseptron
DVM	Destek vektör makineleri
EÇB	En çok benzerlik
EMS	Elektromanyetik spektrum
QB	Quickbird
ISODATA	Iterative Self Organising Data Analysis Techniques (İteratif kendi kendine organize olabilen veri analiz tekniği)
LVQ	Learning vector quantization
NDVI	Normalized difference vegetation index (Normalize edilmiş bitki indeksi)
RBF	Radyal tabanlı ağlar
SOM	Self-organizing map (Özdüzenleyici hartialar)
SWIR	Short wave infrared (Kısa dalga kızılötesi)
TÜBİTAK	Türkiye Bilimsel ve Teknolojik Araştırma Kurumu
WV	Worldview
VNIR	Visible near infrared (Görünür kızılötesi)
YAKA	Yapay arı koloni algoritması
YSA	Yapay sinir ağları

SİMGELER DİZİNİ

cm	Santimetre
D	YAKA Limit değeri için parametre sayısı
KD	Kullanıcı doğruluğu
km	Kilometre
m	Metre
nm	Nanometre
SN	YAKA yiyecek kaynağı sayısı
sn	Saniye
ÜD	Üretici doğruluğu
µm	Mikrometre

1. GİRİŞ

Dünya nüfusunun hızlı artışı, ekonomik faaliyetler gibi etkenler nedeniyle insanoğlunun gıdaya olan ihtiyacı gün geçtikçe artmaktadır. Artan bu ihtiyaç tarım sektörünü önemli bir hale getirmektedir. Tarım alanlarının doğru ve etkin bir biçimde planlanması ve yönetimi ülke ekonomisine katkı sağlamaktadır. Avrupa Birliği Ortak Tarım Politikası toplam Avrupa Birliği bütçesinin yaklaşık olarak % 40'ını oluşturmaktadır ve bu da tarıma verilen önemi açıkça göstermektedir (Sağlık, 2010). Türkiye tarım alanları konusunda dünyanın önde gelen ülkeleri arasında yer almaktadır. Ülkemizde çeşitli tarım ürünleri yetiştirilmekte ve dünyaya sunulmaktadır. Bu ürünlerin önde gelenlerinden biri olarak çay, Türkiye tarım niteliği bakımından önem arz etmektedir. Çay ve benzer nitelikteki tarım alanları ülke kalkınma, planlama ve çiftçi destekleme çalışmaları başta olmak üzere birçok uygulama için hızlı ve doğru bir şekilde belirlenmesi gerekmektedir.

Ulusal ve uluslararası anlamda tarım alanlarının planlanması, izlenmesi ve verimli şekilde kullanılabilmesi adına uzaktan algılama teknolojileri aktif olarak kullanılmaktadır. Uzaktan algılama, herhangi bir fiziksel temas olmaksızın sensörler yardımıyla oluşturulan uydu görüntüleri üzerinden yeryüzündeki nesnelerden bilgi çıkarımı işlemidir (Levin, 1999). Elde edilen uydu görüntüleri birçok meslek disipliniinde aktif olarak kullanılmaktadır. Bu görüntüler çeşitli görüntü işleme ve zenginleştirme yöntemlerine tabii tutularak kullanılabilir hale gelmektedir. Özellikle son yıllarda tarım, doğal bitki örtüsü, ormancılık gibi amaçlara yönelik algılayıcılar ve uydular tasarlanmakta ve bu konudaki çalışmalar hızla devam etmektedir (Üstüner vd., 2014).

Uydu görüntülerinin işlenmesi esasına dayanan uzaktan algılama biliminin en önemli görüntü işleme yöntemlerinden birisi hiç şüphesiz sınıflandırma işlemidir (Atasever vd., 2011). Sınıflandırma işlemi genel olarak yeryüzündeki benzer spektral yansıtma değerine sahip objelerin aynı grup altında toplanması işlemi olarak tanımlanabilir. Diğer bir ifadeyle, görüntüyü oluşturan her bir pikselin tüm bantlardaki değerlerinin diğer pikseller ile karşılaştırılarak benzer piksellerin kullanıcının belirlediği sınıflara

ayrılması işlemidir (Campbell, 1996). Sınıflandırma işlemi iki şekilde yapılabilmektedir. Bunlardan birincisi olan kontrollü sınıflandırma işleminde elde edilecek kategorileri temsil eden görüntü pikselleri toplanır ve ayırt edici karar fonksiyonları bu eğitim örneklerinden hesaplanır. İkinci metot olan kontrolsüz sınıflandırma işleminde ise kategorileri temsil eden örnekler bilinmeyip spektral olarak ayrılabilen kümeler oluşturulur. Kümelerin hangi kategorileri temsil ettikleri sınıflandırmadan sonra arazi incelemeleri ve haritalardan yararlanılarak belirlenir (Kansu, 2006).

Günümüzde sınıflandırmada kullanılan klasik istatistik yöntemlerin (En Çok Benzerlik, En Kısa Mesafe, Mahalonobis Uzaklığı, Paralelkenar Yöntemi vb.) yanı sıra son yollarda yapay zeka uygulamalarından yapay zeka optimizasyon algoritmaları, yapay sinir ağları, uzman sistemler ve bulanık mantık gibi yaklaşımlarda kullanılmaya başlanmıştır. Uydu görüntülerinin sınıflandırılmasında yaygın olarak kullanılan yapay sinir ağları ile görüntü sınıflandırma ilk olarak 1988 ve 1990 yılları arasında yapılan üç çalışma ile ortaya çıkmıştır (Key vd., 1989; Lee vd.,1990; Benediktsson vd., 1990). İlerleyen yıllarda sıklıkla kullanılmaya devam eden bu uygulama günümüzde uydu görüntülerinin sınıflandırılmasında yüksek doğruluk veren algoritmalar arasında kendine yer edinmiştir.

Görüntü sınıflandırmada yüksek doğruluk veren bir diğer uygulama ise yapay zeka optimizasyon algoritmalarıdır. Son yirmi yılda Parçacık Sürü Optimizasyonu, Diferansiyel Gelişim ve Karınca Kolonisi Optimizasyonu gibi Yapay Zeka optimizasyon algoritmaları (sezgisel algoritmalar) birçok meslek disiplinde, değişik optimizasyon problemleri için kendine geniş bir yer bulmuştur (Banerjee, 2012). Bu algoritmalar halihazırda kullanılan klasik sınıflandırma yöntemlerine (en çok benzerlik, en kısa mesafe, paralelkenar yöntemi vb.) bir alternatif olarak kullanılabilmektedir.


Yapay arı koloni algoritması (YAKA) arıların yiyecek arama davranışlarından ilham alınarak geliştirilen bir yapay zeka optimizasyon algoritmasıdır (Karaboğa, 2011). Arılar yiyecek arama davranışlarını sergilemek adına çeşitli salınım ve hareketlerde bulunurlar. Bu hareketler belirli görevlere sahip arılar tarafından izlenerek besin kaynağı hakkında bilgi edinimi sağlar. Yapay arı koloni algoritmasının kullanımı uzaktan algılama alanında henüz çok yenidir ve çok az sayıdaki çalışma ile sınırlıdır. Yapılan bazı çalışmalarda diğer sınıflandırma teknikleri ile karşılaştırılan YAKA'nın

daha yüksek doğruluk verdiđi görülmüştür (Banerjee., 2012; Atasever vd., 2011; Jayanth vd., 2015).

Bu tez çalışmasında YAKA kullanılarak YSA optimize edilmiş sınıflandırma performansının belirlenmesi amacıyla Rize ilinde seçilen iki pilot bölgeye ait 8 bantlı WorldView-2 ve 4 bantlı Quickbird-2 uydu görüntüleri kullanılmıştır. Görüntüler üzerinde ISODATA ve yapay arı koloni algoritması ile kontrolsüz sınıflandırma işlemleri, EÇB, YSA ve YAKA ile kontrollü olarak sınıflandırma işlemleri yapılmıştır. Her iki işlem için 5 adet arazi örtüsü sınıfı kullanılmıştır (ağaçlık, çay, deniz/dere, toprak, yerleşim). Öncelikle uydu görüntülerinin sınıflandırılması için kullanılacak olan kodlar MATLAB yazılımında süzülerek sınıflandırma işlemine uygun hale getirilmiştir. Yiye aynı yazılımda eğitim ve test veri setlerinin karşılaştırılmasında kullanılacak olan kod setleri düzenlenmiştir. ERDAS Imagine yazılımı kullanılarak seçilen eğitim alanları ile MATLAB yazılımı kullanılarak sınıflandırmalar yapılmış ve ArcGIS yazılımında hata matrisleri oluşturularak doğruluk analizleri yapılmış ve kullanılan yöntemler arasında doğruluk karşılaştırmaları yapılmıştır.

2. UZAKTAN ALGILAMA VE TEMEL BİLEŞENLERİ

Uzaktan algılama bir cisimle direkt temas etmeksizin onun fiziksel özellikleri hakkında bilgi etme bilimi olarak tanımlanmaktadır (Çölkesen, 2009). Yeryüzünden belirli uzaklıkta uzayda veya atmosfer dışına yerleştirilmiş uydular tarafından elde edilen cisim bilgileri ham olarak kullanıcılara sunulmaktadır. Harita, jeoloji, tarım, şehircilik gibi bilim dalları uzaktan algılamanın aktif olarak kullanılabildiği bilim dallarıdır. Uzaktan algılama, yeryüzünden yansıyan elektromanyetik enerjinin, elektromanyetik spektrumun görüntü bölgesi olarak adlandırılan kısmında sensörler tarafından ölçülerek değerlendirilmesi esasına dayanır (Orhan, 2014). Elektromanyetik spektrum (EMS), 3×10^8 m/sn hızla hareket eden, dalga uzunluğu nanometreden kilometreye kadar uzanan sürekli enerji ortamıdır. Bütün cisimler az ya da çok elektromanyetik enerji yayarlar. Elektromanyetik spektrum yapılan çalışmalarda kolaylık sağlaması açısından belirli bölgelere ayrılmıştır. Ancak bu bölgeler arasında kesin sınır bulunmamaktadır (Çölkesen, 2009). Şekil 1’de elektromanyetik spektrum ve spektral aralıklar gösterilmiştir. Bölgeler içerisinde 400 nm ve 700 nm ($0.4\mu\text{m}$ - $0.7\mu\text{m}$) arasında kalan kısım görünür bölge olarak adlandırılmaktadır. Bu bölge insan gözünün görebildiği dalga boyu aralığını ifade etmektedir. Görünür bölge içerisinde yaklaşık 400 nm ve 500 nm arasında kısım mavi, yaklaşık 500 nm ve 600 nm arasında kalan kısım yeşil ve 600 nm ve 700 nm arasında kalan kısım ise kırmızı renge karşılık gelen dalga boylarını ifade etmektedir. $0.7\mu\text{m}$ ve $1000\mu\text{m}$ dalga boyları arasında kalan bölgede ise yakın kızılötesi, termal ve uzak kızılötesi bölgeler yer almaktadır. Özellikle yakın kızılötesi dalga boyunda bulunan ışınımın bitkilerde bulunan klorofil pigmentine duyarlıdır ve çalışmalarda bu amaçla sık sık kullanılmaktadır.



Şekil 2.1: Elektromanyetik spektrum ve spektral aralıklar (Ekercin, 2007).

2.1 Uzaktan Algılamada Kullanılan Algılayıcı Sistemler

2.1.1 QuickBird uydu sistemi

İlk QuicBird uydusu 2000 yılının Kasım ayında Rusya Plesetsk uzay üssünden EarthWatch firması tarafından uzaya fırlatılmış, planlanan yörüngeye oturamamış ve başarısızlık olarak ilan edilmiştir (URL-1). 2001 yılında, Vandenberg Hava Kuvvetleri Üssü, Kaliforniya'dan fırlatılan QuickBird 2, Digital Globe adlı özel bir A.B.D. şirketi tarafından çalıştırılmaktadır. QuickBird 2 verisinden, pankromatik bant için 0.61 m.'lik (nadir) çözünürlükte, multispektral bantlar için ise 2.5m.'lik(nadir) çözünürlükte görüntüler elde edilmektedir. Çizelge 2.1'de verilen değerler Quickbird uydusunun teknik özelliklerini göstermektedir.

Çizelge 2.1: Quickbird Uyduyu Teknik Özellikleri (URL-2).

Fırlatılma Yeri ve Zamanı	Vandenberg Hava Kuv. Üssü, Kaliforniya, 2001
Fırlatma Aracı	Boeing DELTA II
Yörünge Yüksekliği	450 Km
Yörünge Eğimi	97°2 Güneş Uyumlu
Hız	7.1 km/sn
Ekvator Geçiş	10:30 am (Alçalan Düğüm Noktası)
Yörünge Zamanı	93.5 dk
Tekrar Geçiş Süresi	1-3.5 gün enleme bağılı olarak (30° nadiren farkı ile)
Tarama Genişliği	16.5 km (nadir)
Metrik Doğruluk	23 m. (yatay)
Çözünürlük	0.61 m. Pankromatik (nadir) 2.44 m. Çok Bantlı (nadir) 0.72 m. Pankromatik - 25° (off-nadir) 2.88 m. Çok Bantlı - 25° (off nadir)
Spektral Bant Genişliği	450 nm – 900nm arası Pankromatik: 450-900 nm Mavi:450-520 nm Yeşil:520-600 nm Kırmızı: 630-690 nm Yakın Kızılötesi:760-900 nm
Dijital Kayıt Formatı	Her piksel için 11 Bit

2.1.2 WorldView uydu sistemi

Worldview uydu sisteminde hâlihazırda kullanılan 3 adet uydu üzerinden veri temini yapmaktadır. Digital Globe şirketi tarafından kullanıma sunulmaktadır. Bunlardan ilki olan Worldview-1 uydusu 2007 Eylül ayında fırlatılmıştır. Uydular arasında en çevik uydu olarak kabul edilmektedir. Yüksek kapasite özelliği yanında 50 cm yersel çözünürlüklü pankromatik (siyah/beyaz) görüntüler sağlayabilmektedir. Worldview1, ortalama 1.7 günlük tekrar ziyaret etme özelliği sayesinde günlük 750.000 km²'lik alanı görüntüleyebilme (50cm çözünürlük) özelliğine sahiptir. Uydu ayrıca yüksek geometrik doğruluk özelliğine sahip olması yanında süratli çekim ve stereo çekim özellikleri de mevcuttur (URL-2).

Worldview uydu sisteminin ikinci uydusu olan Worldview-2 2009 yılının Ekim ayında fırlatılmış olup, dünyanın 8 banda sahip ilk yüksek çözünürlüklü gözlem uydusudur. WorldView-2 uydusu, 770 km. yükseklikte konumlandırılmış olup hem

0.46 m yersel çözünürlüklü pankromatik hem de 1.84 m yersel çözünürlükte multispektral olarak görüntü sağlayabilmektedir. WorldView-2 uydusu ortalama 1.1 günlük yeniden ziyaret etme süresine sahiptir. Günlük 975,000 km²'lik alan çekebilme özelliğine sahiptir (URL-2). Uygulamalarda kullanılacak olan Worldview2 uydusunun teknik özellikleri Çizelge 2.2'de gösterilmiştir.

Çizelge 2.2: Worldview-2: Uydusu Teknik Özellikleri (URL-2).

Fırlatma Bilgileri	Tarih: 8 Ekim, 2009 Fırlatma Aracı: Delta 7920 Fırlatma Alanı: Vandenberg Hava Üssü, Kaliforniya-ABD
Yörünge	Yükseklik: 770 kilometre Tip: Güneş senkronizasyonlu, Periyod: 100 dakika
Uydu Ömrü(Tahmini)	7-25 Yıl
Spektral Bantlar	Pankromatik: 450 - 800 nm, 8 bant Multispektral: Kıyısı: 400 - 450 nm Kırmızı: 630 - 690 nm Mavi: 450 - 510 nm Kırmızı Kenarı: 705 - 745 nm Yeşil: 510 - 580 nm Yakın-IR1: 770 - 895 nm Sarı: 585 - 625 nm Yakın-IR2: 860 - 1040 nm
Yersel Çözünürlük	Pankromatik: 0.46 metre GSD (nadir), 0.52 metre GSD at 20° derece off-nadir Multispektral: 1.84 metre GSD (nadir), 2.08 metre GSD at 20° derece off-nadir
Radyometrik Çözünürlük	11-bit dinamik aralığı
Çerçeve Genişliği	16.4 kilometre (nadir)
Uydu Veri Kapasitesi	2199 gigabit solid state Hard Disk
Maksimum Çekim Açısı	Nominal olarak +/-45° off-nadir
Tek Geçişte Maksimum Alan	65.6 km x 110 km mono (nadir)
Yeniden Geçiş Sıklığı	1.1 gün- 1 m. GSD veya daha az 3.7 gün 20° off-nadir veya daha az (0.52 m. GSD)

Digital Globe şirketinin Worldview serisindeki son uydusu Worldview-3 uydusudur. 19 Ağustos 2014 tarihinde yaklaşık olarak 617 km yükseklikteki yörüngesine yerleştirilmiştir. Worldview-3 dünyanın en yüksek mekânsal çözünürlüğe sahip yer gözlem uydusudur ve önümüzdeki birkaç yıl içerisinde planlanmış daha yüksek çözünürlüğe sahip başka uydu bilinmemektedir (Marchisio, 2013). Pankromatik kanalda yüksek mekânsal çözünürlüğünün (0.31m) yanı sıra, yüksek mekânsal

çözünürlüğe (1.24 m ve 3.7 m) sahip süper çoklu tayf kanallarına da sahiptir. Bunların 8 adedi görünür yakın kızılötesi (VNIR) bölgede, 8 adedi kısa dalga kızılötesi (SWIR) bölgede yer almaktadır (URL-2). WorldView-3 uydusu, tek geçişte 112 x 65.5 km boyutlarında yan yana 5 şerit olarak çekim yapabilme veya 13.1x 360 km uzunluğunda tek şerit veya 26.2 x 112 km boyutlarında setereo görüntüleme ve bir şerit içinde 680,000 km² görüntüleme kapasitesine sahiptir. Özellikle, yüksek mekânsal çözünürlüğe sahip SWIR kanallarının jeolojik uygulamalarda önemli katkılarda bulunacağı tahmin edilmektedir (Erbay, 2014).

Uzaktan algılama günümüzde birçok bilim dalında aktif olarak kullanılmaktadır. Genel olarak uzaktan algılama uygulamaları, yeryüzünün tamamına ait bilgilerin değerlendirilmesi ile ilgilidir. Yenilenen teknoloji ile fırlatılan yeni uydular sayesinde uzaktan algılamanın uygulama alanları genişleme imkânı bulmuştur. Uzaktan algılamanın kullanım alanları Çizelge 2.3’te kısaca verilmiştir.

Bilim Dalı	Çalışma Alanı
Haritacılık	Sayısal arazi modellerinin üretilmesi, Yeryüzü deformasyonlarının izlenmesi, Topoğrafik harita üretimi.
Hidroloji	Su kalitesi analizleri, Su kirliliği izleme, Sel haritalaması ve izleme, Kar dağılımını ve miktarını belirleme, Buz erimesi ve buz hareketi gözlem, Gemi atıklarını izleme.
Tarım	Arazi kullanımının belirlenmesi, Bitki tipini ayırma, Ürün çeşitliliğinin belirlenmesi, Bitki canlılığının izlenmesi, Bitki gelişimini izleme, Rekolte tahmini, Toprak nemi ve türünü belirleme.
Jeoloji- Maden	Jeolojik yapı araştırmaları, Fay, çizgisellik ve kırıkların tanımlanması, Jeotermal araştırmalar, Deprem araştırmaları, Volkanik araştırma çalışmaları ve izleme, Maden ve yeryüzü kaynaklarının aranması, Petrol aramaları, Kayaç tiplerinin tespiti, Petrol sızıntılarının tespiti.
Ormancılık	Orman türlerinin haritalanması; Ağaç hastalıklarının izlenmesi; Ormansızlaşma ve çölleşme izleme; Kereste üretimi tahmini ve planlaması; Orman yangınlarının izlenmesi.
Çevre	Ekolojik gelişmelerin sürekli ve geniş, ölçekte izlenmesi, Arazi örtüsü veya kullanımının haritalanması, Akarsu, deniz ve göl su kirliliklerinin belirlenmesi, Kıyı alanlarındaki değişimlerin izlenmesi, Sanayi alanları ve çevresindeki değişimlerin izlenmesi, Orman alanlarındaki değişimin izlenmesi.
Şehircilik Faaliyetleri	Arazi örtüsü ve kullanımının belirlenmesi, Şehirleşmedeki gelişimin izlenmesi, Zaman içinde meydana gelen değişimlerin belirlenmesi, Altyapı çalışmaları, Kaçak yapılaşmanın tespiti, Planlama çalışmaları, Sayısal yükseklik modeli üretimi.

2.3 Uzaktan Algılamada Görüntü İşleme Teknikleri

Sayısal formatta uydulardan ham halde elde edilen görüntüler kullanım amaçlarına göre değişik yöntemlerle ve sistemlerle düzenlenip ve iyileştirilip kullanıma hazır hale getirilirler. Bunların tamamını uzaktan algılamada sayısal görüntü işleme tekniği olarak nitelendirmek yanlış olmayacaktır. Bu işlemler görüntü işlemeye özel olarak üretilmiş yazılımlar kullanılarak bilgisayarlar vasıtası ile yapılabilmektedir. Görüntü işleme esnasında sayısal görüntü temel olarak 4 safhadan geçmektedir. Bunlar sırasıyla; ön işlem süreci, görüntü geliştirme, görüntü dönüştürme ve sınıflandırma başlıkları altında toplanabilir.

2.3.1 Ön işlem süreci

Uydulardan alınan ham verilerin kullanılabilir hale gelmesi için çeşitli işlem süreçlerinden geçmesi gerekmektedir. Bunlardan ilk basamak olan ön işlem süreci, görüntülerin işlenmeye hazır ve amaca uygun hale gelebilmesi için birtakım düzeltmeleri içermektedir. Bu düzeltmeler radyometrik ve geometrik olarak sınıflandırılır. Bazen bu işlemlere görüntü restorasyonu ve rektifikasyonu adı da verilmektedir. Ön işlem sürecinde amaçlanan, algılayıcıdan kaynaklanan geometrik ve radyometrik hataların giderilmesidir (Çölkesen, 2009).

Geometrik bozukluklar algılayıcı platformun hızı, yüksekliği, tarayıcı hareketi, arazi yüzeyi vb. konularda sabit davranışlar göstermemesinden kaynaklı meydana gelmektedir. Uydulardan ham halde elde edilen veriler sistematik ve rastgele geometrik hatalar ile yüklü olarak elde edilir (Reis, 2003). Sistematik hatalar matematiksel yöntemlerle formülize edilerek elimine edilebilmektedir. Rastgele hatalar ise araziye tesis edilen yer kontrol noktaları yardımı ile düzeltilebilmektedir. Bu hataların giderilmesinden sonra koordinatlı görüntü verisi elde edilir. Elde edilen veriler, temsil ettikleri bölgenin yeryüzündeki gerçek koordinatlarına getirilmiş olur. Radyometrik düzeltmenin amacı uydu görüntülerinin algılanması sırasında ortaya çıkan atmosferik etkileri azaltmak ve uydu görüntüsüne ait piksel parlaklık değerlerini (digital numbers) yersel spektral yansıtma değerleri ile spektral olarak karşılaştırılabilir birime dönüştürmektir (Ekercin, 2007). Bu işlem sürecinde ilk olarak piksel parlaklık değerleri, spektral parlaklık değerlerine daha sonra ise spektral parlaklık değerleri spektral yansıtma değerlerine dönüştürülür.

2.3.2 Görüntü zenginleştirme

Görüntü geliştirme işlemi, geometrik ve radyometrik düzeltmeleri yapılmış görüntülerin daha kolay yorumlanabilir ve anlaşılabilir bir hal almasına olanak sağlar. Bu sayede kullanım amacına uygun olarak istenilen veriler görüntülerde belirginleştirilip istenmeyen öğeler ise bastırılabilir. Görüntüler iyileştirme esnasında histogram dönüşümleri ve birçok filtreleme metodu kullanılmaktadır. Bunlar kontrast artırımı, filtrelemeler ve çok kanallı uydu verilerinin zenginleştirilmesi olarak sıralanabilir. Kontrast artırmanın amacı, bir görüntü üzerindeki gri renk tonlarını daha belirgin hale getirmek ve görüntünün görsel yorumlanabilirliğini artırmaktır (Ekercin, 2007). Bu yöntemde görüntüdeki minimum piksel değeri sıfıra maksimum piksel değeri ise 255 değerine artırılması için bir lineer enterpolasyon yöntemi geliştirilir. Çok bantlı görüntülerde bu işlem her bant için ayrı ayrı uygulanarak elde edilen veriler karşılık gelen bantlara atanır. Histogram eşitleme ile görüntüde parlaklık değerleri ile yapılan operasyonlar sonucu parlaklığın en yoğun bulunduğu bölgeye en yüksek kontrast artırımı yapılmaktadır. Bu yöntemde kontrast artırımına göre daha karmaşık bir yapı kullanılarak ve histogramın boyu ve şekilleri dikkate alınarak operasyonlar gerçekleştirilir. Histogram eşitleme görüntü iyileştirme teknikleri arasında en çok kullanılan ve en iyi sonuç veren metottur. Bu teknikte kenar gruplar birleştirilirken orta gruplar daha ayırık hale getirilip görüntü kalitesi iyileştirilir (Çölkesen, 2009). Filtreleme işlemlerinde amaç, görüntü üzerindeki bozuklukların giderilerek görüntülerin daha iyi ayırt edilebilir ve yorumlanabilir olmasını sağlamaktır. Bu yöntem için alçak ve yüksek geçirgen filtre olmak üzere iki yöntem kullanılmaktadır. Alçak geçirgen filtre ile görüntü kalitesini bozan gürültü ve parazitler giderilirken, yüksek geçirgen filtre kullanımı ile parazitsiz görüntülerde algılayıcı sistemin çözebilirlik sınırında veya altında kalan küçük cisimlerin ayırt edilebilmesini sağlamaktır (Ekercin, 2007). Görüntü dönüştürme yöntemleri ana bileşenler dönüşümü ve oran görüntüleri oluşturma işlemleridir. Ana bileşenler dönüşümü işleminde istenilen veri grupları daha da belirginleştirilerek yeni veri grubundan konu hakkında daha fazla bilgi çıkarımı yapmak amaçlanmıştır. Oran görüntüleri oluşturma işleminde ise görüntü üzerinde bulunan bantlar birbirlerine oranlanarak yapılacak çalışmaya en uygun veri bant birleşimi ve kombinasyonu işlemi yapılır. Bu işlem sonucunda ortaya çıkan ürün, görüntü üzerinde belirginleştirilecek obje grubunu ortaya çıkarmaya yarar.

2.3.3 Sınıflandırma

Uzaktan algılamada en önemli görüntü işleme yöntemlerinden birisi hiç şüphesiz sınıflandırma işlemidir (Atasever vd., 2011). Sınıflandırma işlemi genel olarak yeryüzündeki benzer spektral yansıtma değerine sahip objelerin aynı grup altında toplanması işlemi olarak tanımlanabilir. Diğer bir ifadeyle, görüntüyü oluşturan her bir pikselin tüm bantlardaki değerlerinin diğer pikseller ile karşılaştırılarak benzer piksellerin kullanıcının belirlediği sınıflara veya sınıf sayısına ayrılması işlemidir (Campbell, 1996). Sınıflandırma işleminde amaçlanan yeryüzünde aynı spektral özelliğe sahip veri gruplarının aynı grup altında toplanarak ayırt edilebilirliğin ve yorumlanabilirliğin artırılmasıdır. Sınıflandırma sonucunda oluşan veri tematik veriler olarak adlandırılabilir. Sınıflandırma işlemi üç temel konu üzerinde odaklanmıştır (Ekercin, 2007);

1. Bir görüntüdeki farklı özelliklerin ortaya çıkarılması,
2. Ayırt edilebilir şekillerin ve uzaysal desenlerin ayrımı
3. Bir görüntüdeki zamana bağlı değişimlerin belirlenebilmesi.

Bir görüntüde ortaya çıkarılacak sınıflar kullanıcı tarafından belirlenebileceği gibi, rastgele, sadece sınıf sayısı verilerek de yapılabilmektedir (Lillesand vd., 2007). Bu işlemlerde kullanıcı tarafından sınıfların belirlenmesi kontrollü sınıflandırmaya, sadece sınıf sayısının belirlenerek istatistiksel bir sınıflandırma işlemi ise kontrolsüz sınıflandırma olarak adlandırılmaktadır.

- Kontrolsüz Sınıflandırma

Kontrolsüz sınıflandırma işleminde kullanıcı tarafından bir eğitim verisi kullanılmaksızın algoritmalar aracılığı ile sadece sınıf sayısı belirlenerek veya rastgele sınıf sayısı temel alınarak yapılan sınıflandırma işlemidir. Kontrolsüz sınıflandırma sonucunda ortaya çıkan sınıflar spektral sınıflardır. Çünkü bunlar tamamen görüntü değerindeki doğal gruplara bağlıdır ve spektral sınıfların kimlikleri süreç başında belli değildir (Reis, 2003). Kontrolsüz sınıflandırma işleminde piksellerin atanacağı sınıflar belirlenir ve bu işlem bütün pikseller sınıflandırılana kadar kümeleme şeklinde devam eder. Kontrolsüz sınıflandırma işleminde spektral uzunluğun belirlenmesinde Euklid ve Mahalanobis gibi uzaklıklar kullanılmaktadır. Sıralı kümeleme, istatistiksel kümeleme ve ISODATA (Iterative Self Organising Data Analysis Techniques) gibi farklı kontrolsüz sınıflandırma yöntemleri vardır. Bunlar içerisinde ISODATA algoritması, uygulamada en iyi sonucu vermesi

nedeniyle çalışmalarda yaygın olarak kullanılmaktadır (Csillag, 2000; Reis, 2003; Ekercin, 2007).

- Kontrollü Sınıflandırma

Kontrollü sınıflandırma işlemi, kullanıcı tarafından belirlenen sınıflar için verilen eğitim verileri kullanılmak sureti ile bu verilerin belirli bir metot ile işlenerek sınıflandırılmış görüntü elde etme temeline dayanmaktadır. Bir başka deyişle, analizcinin görüntü üzerindeki verileri kendi deneyim ve çalışmaları sonucunda örnek olarak tanımlaması ve kullanılan algoritmanın bu işlemi verilen örnek alanlara göre sürdürmesi işlemidir. Kontrollü sınıflandırma sonucunda oluşan veriler tematik haritalardır. Oluşturulan haritalar eğitim verilerine göre sınıflara ayrılmış ve belirginleşmiş halde sunulur. Kontrollü sınıflandırma, kontrolsüz sınıflandırma sonucunda üretilen veri setlerini de kullanabilmektedir. Özellikle çok büyük veri setlerinin sınıflandırılmasında her iki sınıflandırma metodunun beraberce kullanılması en iyi neticeyi vermektedir. Müşterek kullanımda kontrolsüz sınıflandırma ile temel sınıflar ortaya çıkarılırken, takiben yapılacak kontrollü sınıflandırma ile kontrolsüz sınıflandırma ile tespit edilmiş sınıfların alt kısımları da belirlenmektedir (İşlem, 2002).

Uydu görüntülerinin sınıflandırılması işlemi kullanılan teknikler bakımından ayırmak mümkündür. Halihazırda kullanılan teknikler (en çok benzerlik, en kısa uzaklık, mahalobis uzaklığı, paralelkenar yöntemi) klasik sınıflandırma teknikleri olarak adlandırılabilir. Son yıllarda ortaya çıkan, sonuçlara gidilmesinde makine öğrenme, bulanıklaştırma, yapay sinir ağları veya yapay zeka gibi algoritmaların kullanılmasına olanak sağlayan teknikleri ise ileri sınıflandırma teknikleri olarak adlandırmak mümkündür.


2.3.3.1 Klasik sınıflandırma teknikleri

En Çok Benzerlik Yöntemi

Maksimum benzerlik yöntemi, literatürde en yaygın kullanılan kontrollü sınıflandırma yöntemidir. Maksimum benzerlik yöntemi, bir pikselin belirli bir sınıfa ait olma olasılığına dayanır. Bu yöntemde sınıflandırılacak piksellerin varyans ve kovaryans değerleri hesaplanır (Ayhan vd., 2003). Sınıflandırma sırasında nokta bulutlarının normal dağılımlı olduğu varsayılarak sınıf deseninin dağılımı, ortalama ve kovaryans matrisi yardımı ile tanımlanabilmektedir. Bu işlemde piksellerin

atanacağı sınıfların belirlenmesi işlemi olasılıksal olarak hesaplanır. Bir pikselin hangi sınıfa ait olduğu her bir sınıfa ait olma olasılıklarının hesabından sonra en yüksek olasılıklı gruba atama şeklinde yapılır (Mather, 1987).

Şekil 2.2’de de özellik uzayı üzerine çizilmiş 3 boyutlu olasılık değerleri değişim grafiği gösterilmektedir;



Şekil 2.2: En çok benzerlik ile tanımlanan olasılık yoğunluk Fonksiyonları (Lillesand vd., 2007).

Olasılık yoğunluk fonksiyonları, her piksel değerinin, herhangi bir sınıfa dahil olma olasılığını hesaplamak için kullanılır. Her bir sınıf için olasılıkların değerlendirilmesinden sonra, pikseller bu değerlerden en olası sınıfa atanır. Herhangi bir sınıfa ait olma olasılığı, belirlenen eşğin altında ise o piksel bilinmeyen sınıf olarak sınıflandırılır. Yöntem pikselleri sadece parlaklık değerlerine göre değil, her sınıf için oluşturulan varyans-kovaryans matrisine göre sınıflandırır. Maksimum benzerlik yönteminin formülü Denklem 2.1’de verilmiştir (Özkan, 2001);

$$D = \ln(a_c) - [0.5 * \ln(|Cov_c|)] - [0.5 * (X - M_c)^t * (Cov_c^{-1}) * (X - M_c)] \quad (2.1)$$

En Kısa Uzaklık Yöntemi

Bu yöntemde her bir örnek sınıf için hesaplanan ortalama vektör ile aday piksel arasındaki uzaklık hesaplanır. Hesaplanan uzaklıklara göre aday piksele en kısa mesafedeki sınıf o piksele atanacak sınıf olarak kabul edilir. En kısa uzaklık yöntemi, maksimum benzerlik yönteminden daha hızlı olduğu için ilgi çekicidir. Ancak kovaryans bilgilerini kullanmadığından maksimum benzerlik yöntemi kadar esnek değildir. Yöntemde kovaryans verilerinin kullanılmaması nedeniyle sınıf modelleri spektral anlamda simetriktir. Bu nedenle bazı sınıflar iyi modellenmeyebilir. Ancak

örnekleme verileri sınırlı olduğu zaman en kısa uzaklık yöntemi, maksimum benzerlik yönteminden daha doğru sonuçlar verir (Özen, 2012).

Paralelkenar Yöntemi

Paralelkenar sınıflandırıcısında her bir örnek sınıfın her bir banttaki en düşük ve en yüksek spektral değerleri dikkate alınarak bölgeler oluşturulur. Daha sonra sınıflandırılmak istenen piksel, içerisinde bulunduğu bölgenin ait olduğu sınıfa atanır (Lillesand vd., 2007). Bu yöntemde, her sınıf için eğitim alanlarındaki sınıf varyanslarına dayalı parlaklık değerlerinin sınırları belirlenir. Bu sınırlar her bir bant için en yüksek ve en düşük parlaklık değerleri ile tanımlanır. Bu sınır değerleri iki boyutlu özellik uzayında paralel kenarlarla ifade edilen bir alan olarak ortaya çıkar. Bilinmeyen bir piksel bu sınır değerleri kullanılarak oluşturulan karar bölgelerine göre sınıflandırılır. Eğer piksel bütün karar bölgelerinin dışında kalıyorsa bilinmeyen olarak sınıflandırılır. Paralel kenarlı bölgelerin çok boyutlu olanları paralel yüzler (paralelepiped) olarak adlandırılır (Ayhan vd., 2003). Paralelkenar sınıflandırıcısı kabul görmüş bir sınıflandırıcı olmasına rağmen barındırdığı dezavantajlardan dolayı tercih edilen bir sınıflandırma yöntemi değildir. En önemli dezavantajı ise sınıflandırma sonucunda ortaya birçok sınıflandırılmamış pikselin çıkmasıdır. Diğer bir dezavantajı ise eğitim verilerinin üst üste çakışması sorunudur. Bu nedenlerle çok fazla tercih edilen bir sınıflandırma yöntemi değildir.

2.3.3.2 Uzaktan algılamada yeni görüntü sınıflandırma yaklaşımları

Uzaktan algılamada kullanılan sınıflandırma teknikleri kullanıcıların ihtiyaç duyduğu doğruluk oranına bağlı olarak değişiklikler gösterebilmektedir. Klasik sınıflandırma yöntemleri, işlemler için birçok kısıtlamalar ve matematiksel çözümsüzlükler ortaya çıkarmaktadır. Klasik sınıflandırma algoritmaları genel anlamda çözüme odaklanırken bir nesne veya problem üzerinde kısıtlı aramalar ve sınırlamalar içerisindedirler. Bu nedenle klasik sınıflandırma algoritmaları geniş çaplı problemler için her zaman iyi çözümler üretemeyebilir.

Uzaktan algılama bilimi arazi örtüsü/kullanımı adına iyi bir veri kaynağıdır. Son yirmi yılda sınıflandırma yapmak için yapay sinir ağları, istatistiksel sınıflandırıcılar ve diğer yapay zeka optimizasyonları gibi nümerik yöntemler ortaya konmuştur (Wilkinson, 1996). Ancak istatistiksel sınıflandırıcılar bazı kısıtlamalar barındırmaktadır. Örneğin uzaktan algılamada en yaygın olan en çok benzerlik

algoritması bilinen ve bilinmeyen piksellerin istatistiksel yaklaşım sonucu belirlenmesi esasına dayanır (Strahler, 1980). Günümüzde ortaya çıkan yeni sınıflandırma teknikleri ve optimizasyon algoritmaları sınıflandırma probleminde klasik yöntemlere göre daha doğru sonuçlara yaklaştığı söylenebilir. Yapay zeka optimizasyon teknikleri çok karmaşık yapılarda verilerin ayrıştırılması işleminde istatistiksel yöntemlerden daha iyi sonuçlar elde etmektedir (Liu vd., 2008). Bu yöntemler fonksiyonun optimum değerine ulaşmayı hedeflerler. En basit anlamda optimizasyon eldeki kısıtlı kaynakları en optimum biçimde kullanmak olarak tanımlanabilmektedir. Yani optimizasyon bir problemin çözümü için elde edilen sonuçlardan en iyisini seçme işidir (Sevim, 2013). Belirli sınırlamaları sağlayacak şekilde, bilinmeyen değerlerin bulunmasını kapsayan herhangi bir problem, optimizasyon problemi olarak adlandırılabilir. Uzaktan algılamada da sınıflandırma problemleri optimizasyon problemi sistematığına uymaktadır. Optimizasyon işleminde öncelikli olarak değişkenler parametre setinin tanımlanması gerekmektedir. Daha sonra bu parametrelere bağlı olarak minimize edilecek bir maliyet fonksiyonu veya maksimize edilecek bir kâr fonksiyonunun tanımlanması gerekmektedir (Karaboğa, 2011). Yani sınıfların atanırken hangi yönteme göre atanacağını gösteren ve en doğru biçimde atanması için çalışan bu fonksiyonlardan, maliyet fonksiyonu, daha iyi çözümü temsil eden parametre değerlerinin kullanılması durumunda daha düşük bir nümerik değer üretirken, kâr fonksiyonu ise daha yüksek bir nümerik değere ulaşmaktadır. Arı koloni algoritması, karınca koloni algoritması gibi algoritmalar son yıllarda uzaktan algılamada kullanılmaya başlanmış ve kayda değer olumlu sonular üretmişlerdir. Karınca koloni optimizasyon algoritmasında karınca sürülerinin zekası modellenirken arı koloni algoritmasında arıların doğada yiyecek arama davranışları modellenmiştir. Her iki uygulama da optimizasyon mantığı ile çalışırlar fakat kullandıkları yöntem ve model birbirinden farklıdır. Bu algoritmaların ortak özelliği yiyecek arama sırasında karınca ve arıların zeki davranışlarının modellenmiş olması ve bu iki sürü zekasının da en uygun ve en rahat ulaşılabilir yiyecek kaynağına ulaşılması mantığı ile çalışmalarıdır. Bu bölümde yeni ve ileri sınıflandırma teknikleri olarak adlandırılan bazı yöntemlerden kısaca açıklanacaktır.

Destek Vektör Makineleri (DVM) istatistiksel öğrenme teorisine dayalı bir kontrollü sınıflandırma algoritmasıdır (Çölkesen, 2009). Genel anlamda istatistiksel öğrenme,

sonlu sayıda eğitim verisi kullanan tahmin fonksiyonunun öğrenilmesini sağlayan öğrenme makinesi veya algoritmanın oluşturulması olarak tanımlanabilir (Atasever, 2011). Kontrollü sınıflandırmada problemin çözümü için sınıflandırılacak veriye ait örnekleri içeren eğitim ve test verileri kullanılır. Eğitim setindeki her bir örnek, öznitelik verilerini ve bu verilere ait sınıf etiketlerini içermektedir. DVM'nin amacı sadece öznitelik değerleri belli olan test setindeki verilerin sınıf etiketlerini tahmin edecek bir model oluşturmaktır. Sınıflandırma işleminde ortaya çıkan bir diğer yenilikçi yöntem ise yapay sinir ağlarıdır. Yapay sinir ağları ile kontrollü öğrenme işleminde, eğitimi temsil eden bağlantı ağırlık değerleri, iteratif bir şekilde ağına ürettiği çıkışların hedef çıkışlarla karşılaştırılmasıyla elde edilen bir hata değerinin minimize edilmesi ile yenilenirken, kontrolsüz öğrenme işleminde, ağırlık değerlerinin yenilenmesi giriş örneğine en büyük benzerlik değerini üreten işlemci elemanın aktifleşmesi ile gerçekleşmektedir (Çölkesen, 2009). Yapay sinir ağları ile uydu görüntülerinin sınıflandırılması son yıllarda birçok çalışmada karşımıza çıkmaktadır. Bölüm 3'te yapay sinir ağları ile görüntü sınıflandırma işlemine ayrıntılı olarak değinilecektir. Yeni gelişen sınıflandırma ve makine öğrenme algoritmaları arasında bulunan karar ağaçları da literatürde yaygın kullanımı bulunan bir sınıflandırma yöntemidir. Bu yöntemin sıkça kullanılmasının nedenin arkasında ağaç yapılarının ve oluşturulan kuralların basit ve anlaşılabilir yapıda olması bulunmaktadır. Karar ağaçları sınıflandırma işlemini gerçekleştirirken çok aşamalı ve ardışık bir yaklaşım kullanmaktadır. Yöntem uydu görüntülerinin sınıflandırılmasındaki gibi karışık sınıflandırma problemlerini aşamalı bir hale getirerek daha basit karar verme olanağı sağlamaktadır (Kavzoğlu ve Çölkesen, 2010). Bir karar ağacı yapısı düğüm, dal ve yaprak olarak adlandırılan üç temel kısımdan meydana gelmektedir. Ağaç yapısında her bir öznitelik yani her bir uydu görüntüsü için bant değeri bir düğüm tarafından temsil edilir. Ağaçta en son kısım yaprak, en üst kısım ise kök olarak adlandırılmaktadır. Kök ve yapraklar arasında kalan kısımlar ise dal olarak ifade edilmektedir.

3. YAPAY SİNİR AĞLARI

Yapay Sinir Ağları (YSA), insan beynin özelliklerinden olan öğrenme yolu ile yeni bilgiler türetebilme, oluşturabilme ve keşfedebilme gibi yetenekleri, herhangi bir yardım almadan otomatik olarak gerçekleştirebilmek amacı ile geliştirilen bir bilgisayar öğrenme algoritmasıdır. YSA insan beyninden esinlenerek, öğrenme sürecinin matematiksel olarak modellenmesi olarak tanımlanabilir. YSA, eğitim verileri aracılığı ile problemi öğrenme ve daha sonra yeni bir verinin tanımlanmasını yapabilme özelliğinden dolayı sezgisel algoritmalar grubunda yer alır (Çölkesen, 2009). Günümüzde YSA geçmişten günümüze birçok meslek disiplinde aktif olarak kullanılmıştır (Demuth ve Beale, 1993) (Torrecila vd., 2004) (Schaap vd., 1998) (Lee vd., 2004). Yapay sinir ağlarının avantajları aşağıda sıralanmıştır (Kavzoğlu, 2001);


- Parametrik olmayan yapıya sahiptirler,
- Keyfi karar sınır yeteneklerine sahiptirler,
- Farklı veri türlerinin ve girdi yapılarının birleştirilmesi kolaydır,
- Özellikle çoklu resimlerde daha iyi genelleştirme yapabilmektedirler,
- Gürültü için toleranslıdır,
- Sınıflandırma için bulanık çıkış değerleri verebilirler.

YSA'nın bu avantajları arasında en önemli olanı parametrik olmayan yani verinin dağılımı ile ilgili herhangi bir ön bilgiye ihtiyaç duymamasıdır. YSA genel olarak güçlü bir sınıflandırıcı yapısı olsa da bir takım olumsuz yönleri bulunmaktadır. Bunlar; kısmen daha fazla eğitim zamanı gerektirmesi, en etkili ağ yapısının belirlenmesi ve sınıflandırma doğruluğunun parametre değişimlerine karşı duyarlı olması olarak ifade edilebilir (Çölkesen, 2009). Bu nedenlerden dolayı ağ yapısı, eğitim zamanı ve sınıflandırma sonuçları direkt olarak etkilenebilir. Günümüze kadar birçok yapay sinir ağı modeli ve öğrenme algoritması geliştirilmiş ve çeşitli derecelerde

başarılar elde edilmiştir. Yapay ağ modellerini iki kritere göre kategorize etmek mümkündür. Bunlardan ilki modelin kontrollü veya kontrolsüz öğrenme stratejilerinden hangisini uyguladığıdır. Kontrolsüz yapay sinir ağı modellerine örnek olarak self-organizing map (SOM), Hopfield ağları ve Grossberg ağları gösterilebilir. Perseptron, çok katmanlı perseptron (ÇKP), radyal tabanlı ağlar (RBF) gibi modeller ise kontrollü öğrenme prensibine göre geliştirilmiş YSA modellerindendir (Çölkesen, 2009). İkinci bir kriter ise ağ modelindeki öğrenme yönü ile ilgilidir. Eğer bilgi akışı girdi katmanından çıktıya doğru ilerliyorsa bu yöntem ileri beslemeli ağ olarak tanımlanmaktadır. Eğer bilgi akışı çıktı katmanından girdi katmanına doğru ilerliyorsa bu öğrenme yöntemi geri beslemeli ağ yapısı olarak tanımlanmaktadır.

3.1 Yapay Sinir Ağlarının Çalışma Prensibi

Yapay sinir ağları, insan beyninin çalışma prensibi ve işlevleri modellenerek oluşturulmuş bir yapıya sahiptir. İnsan beyninin yapısının karmaşıklığı dolayısı ile açıklanması ve basit bir şekilde modellenmesi kolay değildir. İnsan beynini genel yapısı ve işleyişi yapay sinir ağlarının anlaşılması açısından önem arz etmektedir. Sinir sisteminin ve insan vücudunun yönetim mekanizması olan beyin, vücudun çeşitli organlarından gelen bilgileri alır, işler ve bunlar hakkındaki kararları vücudun ilgili birimlerine aktarır. İnsan beyni milyonlarca hücre yapısından oluşan devasa bir yaradılış harikasıdır. Her bir hücre birbirine nöron adı verilen bağlantılar ile bağlanmıştır. Nöronlar beyin yapı taşlarını oluşturan ve karar verme sisteminde önemli görevler üstlenen temel yapı taşlarıdır. Nöronların genel yapısı içerisinde dendrit, akson, çekirdek ve sinaps olarak adlandırılan bileşenler bulunmaktadır (Kavzoğlu, 2001). Şekil 3.1’de biyolojik bir nöronun genel fiziki yapısı gösterilmiştir. Burada, dentritler nöron çekirdeğine girdi verilerini temin etmektedirler. Dentritlerden gelen bilgiler çekirdekte işlenerek aksona gönderilir. Son kısımda bulunan sinapslar diğer nöronlarla aradaki iletişimi sağlar. Çekirdekte işlenen ve analiz edilen sinyaller çıktıya dönüştürülerek diğer nöronlara gitmek üzere akson ve sinapslara yönlendirir.



Şekil 3.1: Biyolojik nöronun genel yapısı (Atasever, 2011).

YSA'nın beyinle olan benzerlikleri aşağıdaki gibidir (Özkan, 2001);

- YSA bilgiyi eğitim ile elde eder,
- Sinaptik ağırlıklar olarak bilinen işlemci elamanlar (yapay nöronlar) arası bağlantı değerleri bilgiyi saklamak için kullanılır.


Yapay nöronlar, aralarında bağlar oluşturarak ve tabakalar halinde gruplandırılarak yapay sinir ağlarını oluştururlar. Yapay sinir ağlarının temel işlem elemanı olan yapay nöronlar biyolojik nöronların dört temel bileşenine benzer dört farklı yapıya sahiptirler. YSA ve biyolojik sinir sisteminin benzerlikleri Çizelge 3.1'de verilmiştir.

Çizelge 3.1: Biyolojik sinir sistemi ve YSA benzerlikleri.

Biyolojik Sinir Sistemi	Yapay Sinir Ağları Sistemi
Nöron	İşlem Elemanı
Dentrit	Toplam Fonksiyonu
Akson	Eleman Çıkışı
Sinapslar	Ağırlıklar

Basit bir YSA yapısında girdi değerlerinden her biri bir ağırlık ile çarpılır. Bu çarpımlar toplanarak bir uygulama fonksiyonuna yönlendirilir. Ardından uygulama fonksiyonundan elde edilen sonuçlar çıktı katmanına gönderilir ve yapı tamamlanmış olur. Şekil 3.2' de basit bir yapay nöronun yapısı gösterilmiştir. Burada, x_i , $i=0,1,2...n$ şeklinde ifade edilen girdi verileridir. w_i ile temsil edilen bağlantı ağırlık

değerlerini göstermektedir. Bu verilerin çarpım ve toplamı sonucunda üretilen değerler uygulama fonksiyonunda işlenir ve çıktı katmanına gönderilir.



Şekil 3.2 Yapay nöronun genel yapısı ve bileşenleri.

Uygulama fonksiyonu yapay sinir ağlarına doğrusal olmayan bir yapı kazandırır. Kullanılan uygulama fonksiyonu doğrusallık gösterdiğinde yapay sinir ağlarının işlemsel yapısı da doğrusal bir tavır takınacaktır. Çok katmanlı perseptronlu YSA yapılarında genellikle logaritmik sigmoidal veya tanjant hiperbolik uygulama fonksiyonları kullanılır. Radyal tabanlı yapılarda ise Gauss uygulama fonksiyonu kullanılmaktadır (Atkinson ve Tatnall, 1997). Bundan dolayı kullanılacak uygulama fonksiyonu oluşturulacak YSA ve çözülecek probleme göre seçilmelidir.

3.2 Yapılarına Göre Yapay Sinir Ağları

Yapay sinir ağları içerdiği yapay nöronların yapılarına ve birbirlerine bağlanış şekillerine göre ikiye ayrılmaktadır. İleri ve geri beslemeli yapay sinir ağları olarak adlandırılan bu iki tür alt başlıklarda incelenecektir.

3.2.1 İleri beslemeli yapay sinir ağları

İleri beslemeli bir yapay sinir ağında nöronlar genellikle katmanlara ayrılmış durumdadırlar (Özkan, 2001). Girdiler, giriş katmanından çıkış katmanına doğru tek yönlü bir iletim halindedir. Aynı katman içerisinde bulunan yapay nöronların bağlantıları bulunmaz. Fakat bir katmanın tüm nöronları bir üst katmanın nöronları ile bağlantılıdır. Bu tip ağlarda herhangi bir andaki çıkış o andaki giriş vektörünün bir fonksiyonu olarak tanımlanabilir. İleri beslemeli ağlara örnek olarak çok katmanlı perseptron (Multi Layer Perseptron-MLP) ve LVQ (Learning Vector Quantization) verilebilir.

3.2.2 Geri beslemeli yapay sinir ağıları

Geri beslemeli yapay sinir ağılarında nöron çıkışları bir önceki katmana veya kendi katmanındaki bir diğer nörona girdi olarak bağlanabilen bir yapıya sahiptir. Geri besleme, bir katmandaki hücreler arasında olduğu gibi katmanlar arasındaki hücreler arasında da olabilir. Bu yapısı ile geri beslemeli YSA, dinamik bir hafızaya sahiptir. Diğer bir ifadeyle herhangi bir andaki çıkış, o andaki girişlerin fonksiyonu olduğu gibi daha önceki giriş ve çıkış değerlerini de yansıtmaktadır. Geri beslemeli yapay sinir ağılarına örnek olarak SOM (Self Organizing Map) verilebilir.

3.3 Öğrenme algoritmalarına göre yapay sinir ağıları

Öğrenme hareketleri genel anlamda eğitim ve tecrübenin genel davranışta meydana getirdiği değişiklikler olarak tanımlanabilir. Yapay sinir ağıları öğrenme algoritmalarına göre kontrollü, kontrolsüz ve takviyeli öğrenme olarak üç başlık altında toplanır.

3.3.1 Kontrollü öğrenme

Kontrollü öğrenme algoritmasından ağa girdi verisi olarak sınıf etiketlerini ve bilgilerini içeren eğitim verileri girilir. Bu öğrenme yönteminde ağ girdi ile çıktı arasındaki sınıf etiketlerine göre ağırlık değerlerini günceller ve girdi ve çıktı arasındaki sınıf etiketleri farklarından bir hata elde ederek yeni verilecek ağırlıkları bu hata payına göre düzenler. Hata hesaplanırken ağırlık bütün çıktı değerleri ile beklenen çıktı değerleri arasında ki fark hesaplanır ve nöron başına düşen hata bulunur (Özkan 2001). Bu işlemden sonra her nöron kendine gelen ağırlıklara göre kendini günceller. Bu algoritmaya örnek olarak LVQ (Kohenn, 1998) algoritması gösterilebilir.

3.3.2 Kontrolsüz öğrenme

Kontrolsüz öğrenme algoritmasında istenilen çıkış değerlerinin bilinmesine gerek yoktur. Yani, ağırlık bir eğitim verisi ile eğitilmesi gerekmemektedir. Ağ girdi olarak sınıf etiketleri belli olmayan öznitelik verileri verilmesi yeterlidir. Girişte verilen örnekten elde edilen çıkış bilgisine göre ağ, kendi sınıflandırma kuralını kendi geliştirebilmektedir. Ağ bağlantı ağırlıklarını aynı özellikte olan dokuları ayırt edebilecek şekilde düzenleyerek öğrenme işlemini tamamlar (Özkan, 2001).


Kontrolsüz öğrenme algoritmasına SOM (Self Organizing Map) (Kohenn, 1998) örnek olarak gösterilebilir.

3.3.3 Takviyeli öğrenme

Takviyeli öğrenme algoritması kontrollü öğrenme algoritmasının özel bir formudur. Kontrolsüz öğrenme algoritmasında olduğu gibi takviyeli öğrenme algoritmasında da giriş verilerine ait herhangi bir sınıf etiketi kullanılmamaktadır. Bu algorithmada ağı her iterasyonu sonucunda ürettiği sonucun iyiliği veya kötülüğüne dair bilgi verilir. Bu bilgilere göre ağ kendini yeniden günceller. Bu sayede ağ hem öğrenerek hem de sonuç çıkararak işlemeye devam eder. Bu algorithmada bir hedef verilmemekte fakat elde edilen çıkışın girişe karşılık uygunluğunu kontrol eden bir kriter kullanılmaktadır.

3.4 Çok Katmanlı Perseptron

Çok katmanlı perseptron, giriş nöronlarının bulunduğu giriş katmanı, çıkış nöronlarının bulunduğu çıkış katmanı ve bir veya daha fazla gizli katmandan oluşmaktadır. Günümüzde en çok bilinen ileri beslemeli ağ yapısı çok katmanlı perseptrondur. Çok katmanlı perseptron doğrusal olmayan bir yapıya sahiptir. Giriş katmanındaki veriler sadece gizli (ara) katmandaki işlemci elemanlara dağıtan bir görev taşırlar. Gizli katmanlar hesaplama işlemleri ile yükümlüdürler ve her bir düğüme ilişkin değerler girdi düğümü ile bu düğüme gelen bağlantılara ait ağırlıkların çarpımının toplamından elde edilir. Çıktı katmanı son işlem katmanıdır ve tanımlı sınıflara ait bir takım kodları sahiptirler. Bir değer ara bağlantılardan geçerken ara düğüm bağlantılarındaki ağırlıklarla çarpılır (Kavzoğlu ve Reis, 2008). Şekil 3.3'te çok katmanlı perseptron yapısı gösterilmektedir.



Şekil 3.3: Dört tabakalı ileri beslemeli çok katmanlı perseptron.

3.5 Yapay Sinir Ağları ile Uydu Görüntülerinin Sınıflandırılması


Uydu görüntülerinin sınıflandırılması için birçok sınıflandırma algoritması kullanılmaktadır. Klasik sınıflandırma yöntemleri olarak da bilinen, en çok benzerlik, en kısa mesafe veya paralelkenar sınıflandırıcısı gibi parametrik sınıflandırma yöntemleri sınıflandırmada farklı ölçeklerde ve boyutlarda veri sınıflandırmasında zorlanmaktadırlar. Ayrıca bu yöntemler istatistiksel sınırlanmalar ve dağılımlara yüksek bağlılık göstermektedirler. Bu sınırlandırmaları aşmak ve daha iyi bir sınıflandırma yapmak amacı ile parametrik olmayan, yapay sinir ağları, en yakın komşuluk ve karar ağaçları gibi sınıflandırma yöntemlerine başvurulmaktadır (Ndehedehe C., vd.). Yapay sinir ağlarının bilgisayar destekli arazi sınıflandırması işlemlerinde alternatif yapıda iyi bir sınıflandırıcı olduğu yapılan çalışmalarda görülebilmektedir (Hepner vd., 1990; Huang ve Lippmann, 1987).

Yapay sinir ağları ile kontrollü öğrenme işleminde, eğitimi temsil eden bağlantı ağırlık değerleri, iteratif bir şekilde ağırlık ürettiği çıkışların hedef çıkışlarla karşılaştırılmasıyla elde edilen bir hata değerinin minimize edilmesi ile yenilenirken, kontrolsüz öğrenme işleminde, ağırlık değerlerinin yenilenmesi giriş örneğine en büyük benzerlik değerini üreten işlemci elemanın aktifleşmesi ile gerçekleşmektedir (Çölkesen, 2009). Yapay sinir ağlarında ağırlık eğitilmesi için bir takım işlemler yapılması gerekmektedir. Bunlar; ön işlemler, ağ giriş ve çıkışının kodlanması, sınıfların çıkarılması, ağ topolojisinin oluşturulması ve ağırlık eğitilmesi ve genelleştirilme kabiliyetinin testi olarak sıralanabilir (Çölkesen, 2009).

Ön işlemlerde amaçlanan yapay sinir ağlarının performansını etkileyecek işlemlerle performansı daha da iyileştirmektir. Bu doğrultuda kullanılan uydu görüntüsü piksel değerlerinin üzerinde yapılacak oynamalar ile yapılabilir. Ana bileşenler dönüşümü yapılarak girdi boyutu azaltılabilir. Piksel değerleri ile beraber doku bilgileri gibi yardımcı bilgiler kullanılabilir. Bu işlemler ağda bir takım değişiklikler de meydana getirebileceği için işlenmemiş ham piksel değerlerinin kullanılması ağı daha uygulanabilir kılmaktadır.

İstatistiksel sınıflandırma algoritmaların çoğunda olduğu gibi temel giriş kodlaması yapay sinir ağlarında piksel örneklerinin tek tek kullanılması şeklindedir. Giriş verisi olarak ilgili örnek için spektral bant sayısı kadar giriş katmanı işlemci elemanı kullanılması en yaygın kullanılan tekniktir. Yapay sinir ağlarında eğitim için kullanılacak verilerin ölçeklenmesi önemli bir husustur (Çölkesen, 2009). Bu

bağlamda çok katmanlı perseptron yapılarında özellikle tanjant hiperbolik-sigmoid veya logaritmik sigmoid aktivasyon fonksiyonları kullanılarak verinin $[0,1]$ veya $[-1,+1]$ aralığına çekilmesi sağlanmaktadır. Bu fonksiyonların kullanılması ağıın işlemsel etkinliğini artırmada olumlu bir etki yaratmaktadır. Yapay sinir ağları ile yapılan bir sınıflandırma işleminde uzaktan algılamada giriş verisi olarak kullanılan her bir bant $[0,1]$ veya $[-1,+1]$ değerleri arasında ölçeklenmektedir. Ölçekleme işlemi ile daha geniş bir aralıkta ifade edilen veriler daha dar bir aralıkta ifade edilerek eğitim işlemleri daha hızlı ve kolay olmakta ve sınıflandırma performansı artırılmaktadır. Şekil 3.4 te tanjant hiperbolik sigmoid ve logaritmik sigmoid aktivasyon fonksiyonlarının işlem grafikleri verilmiştir. Denklem 3.1’de logaritmik sigmoid transfer fonksiyonuna ait ve Denklem 3.2 de tanjant sigmoid fonksiyonuna ait eşitlikler verilmiştir.



Şekil 3.4: Logaritmik sigmoid fonksiyonu giriş-çıkış eğrisi (A), tanjant sigmoid fonksiyonu giriş -çıkış eğrisi (B) (Altun vd., 2010).

$$x = \frac{1}{1+e^{-y}} \quad (3.1)$$

$$x = \frac{2}{1+e^{(-2y)}} - 1 \quad (3.2)$$

Ağ çıkışının kodlanmasında en doğal yöntem her bir sınıf için ayrı bir işlemci elemanın kullanılmasıdır. Bu sayede pikseller en yüksek çıkış değerini aldığı işlemci elemanın temsil ettiği sınıfa atanır. Yüksek çıkış değerinin alınması o pikselin atandığı sınıfa aitliğinin yüksek doğrulukta olduğunu ifade eder. Yapay sinir ağlarında giriş-çıkış katmanındaki işlemci eleman sayısı, veri boyutu ve istenen sınıf sayısı gibi etkenlere bağlı olarak belirlenebilirken gizli katmanlardaki elemanlar deneme yanılma yolu ile belirlenmektedir.

Çok katmanlı perseptron yapılarının eğitilmesi için kullanılan geri yayılım algoritmasında eğitim, ya örneklerin ağa bireysel girişlerinden elde edilen hata miktarına göre veya toplu halde ortaya çıkan hata miktarına dayanarak elde edilir.

Genel olarak YSA eğitimi aşağıdaki aşamaları barındırmaktadır (Çölkesen, 2009);

- Eğitim ve buna karşılık gelecek çıkış verilerinin belirlenmesi,
- Ağ topolojisinin yani giriş, ara ve çıkış katman sayısının belirlenmesi,
- Başlangıç ağırlık değerlerinin atanması. Bu değerler rastgele değerlerdir. Aksi halde ağ içerisinde dağıtılmış farklı ağırlık değerlerine ulaşmak mümkün olmamaktadır.
- Öğrenme ve momentum gibi gereken ağ parametrelerinin belirlenmesi.
- Çıkış kodlarının belirlenmesi.

Uzaktan algılanmış verilerin yapay sinir ağları ile sınıflandırılması adına birçok çalışma mevcuttur. Literatürde görülen ilk çalışmalardan biri uzaktan algılanmış görüntülerin analizi ile ilgili olarak Key vd. (Key vd., 1989) tarafından yapılmıştır. Çalışmada arktik bölgeye ait 5 kanallı AVHRR verisiyle 2 kanallı SMRR verisinin birleştirilmiş görüntüleri, 4 arazi ve 8 bulut sınıfı için geri yayılma öğrenme algoritması ile sınıflandırılmıştır. Sonuçlar en çok benzerlik yöntemi ile kıyaslanmış ve yapay sinir ağlarının avantaj ve dezavantajları irdelenmiştir.

Heermann ve Khazenie (1992) tarafından yayınlanan çalışmada geri beslemeli yapay sinir ağlarının uzaktan algılanmış verilerini sınıflandırılmasında kullanılması araştırılmıştır. Elde edilen sonuçlar istatistiksel bağlamsal teknik, kontrollü parçalı lineer sınıflandırıcı ve bir kontrolsüz sınıflandırma algoritması ile karşılaştırılmış ve yapay sinir ağlarının kullanılabilirliği irdelenmiştir.

Miller vd. tarafından yapılan çalışmada (Miller vd., 1995) uzaktan algılanmış verilerin sınıflandırılması için yapay sinir ağları kullanılmış, doku verileri eklenerek ağın genel kabiliyetinin artırılabilirdiği fakat özel bitki türleri arasında ayırım kapasitesinin azaldığı gözlenmiştir. Yapay sinir ağları için gerekli sınıflandırma prosedürleri tespit edilmeye çalışılmıştır.

Atkinson ve Tatnall (1997) tarafından yapılan çalışmada yapay sinir ağlarının uzaktan algılamada gelişimi ve kullanımı araştırılmıştır. Çok katmanlı perseptron yapısının sınıflandırma işlemlerinde kullanımı incelenmiş ve arazi ve bulut sınıflandırmasında kullanımı irdelenmiştir.

Özkan (2001) tarafından yapılan çalışmada çok spektrumlu LANDSAT TM uydu görüntüsü verisinin sınıflandırılması için hem klasik en çok benzerlik yöntemi ile farklı yapay sinir ağları sınıflandırma algoritmalarının karşılaştırılması, hem de kullanılan yapay sinir ağlarının kendi aralarında karşılaştırılması yapılmıştır. Çalışma sonucunda yapay sinir ağlarının sınıflandırma işlemlerinde avantaj ve dezavantajları incelenmiştir.

Kavzoğlu ve Reis (2008) tarafından yayınlanan çalışmada yapay sinir ağları ve en çok benzerlik yönteminin Landsat ETM+ görüntülerinin sınıflandırılmasındaki performansları incelenmiştir. Araziden alınan eğitim ve test verileri kullanılarak 8 arazi kullanım/örtüsü sınıfı belirlenmiş ve sınıflandırma yapılmıştır. Sonuç olarak yapay sinir ağlarının multispektral verilerde arazi örtüsü sınıflandırmada daha iyi sonuçlar verdiği gözlemlenmiştir.

Çölkesen (2009) tarafından yapılan yüksek lisans tezinde çeşitli sınıflandırma algoritmaları karşılaştırılmıştır. Landsat ETM+ ve Terra ASTER verileri kullanılarak yapılan bu çalışma yapay sinir ağlarının klasik sınıflandırma tekniği olan en çok benzerlik yöntemine göre daha iyi sonuçlar verdiğini göstermiştir.

Ndehedehe vd. (2013) tarafından yayınlanan çalışmada arazi örtüsü/arazi kullanımı sınıflandırması yapmak amacı ile Landsat 7 görüntülerinin sınıflandırılması için beş farklı sınıf oluşturulmuş. Mevcut ortofotolar kullanılarak doğruluk sonuçlarına ulaşılmıştır. Burada iyi bir doğruluk isteniyorsa yapay sinir ağının gizli katmanının bir tane olması gerektiği vurgulanmıştır. Geleneksel yöntemlere göre yapay sinir ağlarının daha büyük veri işlemede daha iyi sonuçlar verdiğini gözlemlenmiştir.

Iounousse vd. (2015) tarafından yayınlanan bir çalışmada olasılıksal yapay sinir ağları kullanarak arazi kullanım sınıflandırması için kontrolsüz yaklaşım geliştirilmiştir. Çalışmada Landsat ve Spot uydu verileri kullanılarak NDVI (Normalize Edilmiş Bitki İndeksi) oluşturulmuştur. Yöntemde kümeleme için Ward metodu kullanılmıştır. Yöntem fuzzy sınıflandırıcı ve K-means sınıflandırıcı ile karşılaştırılmış ve olasılıksal yapay sinir ağları yönteminin % 3.44 gibi bir doğruluk performansı artışı gösterdiği gözlemlenmiştir.

4. YAPAY ARI KOLONİ ALGORİTMASI (YAKA)

Doğada var olan sürü zekâları, araştırmacıları bu zekâları problemlere uygulamak ve çözmek için çabalara yönlendirmiştir. YAKA, Karaboğa tarafından, arıların doğada içgüdüsel olarak var olan yiyecek arama davranışlarını modellemesi sonucu ortaya çıkmıştır (Karaboğa, 2005). YAKA, gerçek arıların doğada besin toplayışını modeller. Bal arıları optimal besin kaynağı bulmak ve yenilerini keşfetmek adına yuvalarında bir dans sergilerler. Bu dansın modellenmesi bilim adamlarını yeni bir sürü zekâsını modellemeye itmiştir.

Yapay arı koloni algoritması basit yapıda, daha kolay uygulanabilir ve daha az kontrol parametresi kullanmasından dolayı yapay sinir ağları, kısıtlı optimizasyon problemleri ve bazı mühendislik problemlerinde başarıyla uygulanmıştır (Zou vd., 2010; Karaboğa ve Bastürk, 2007; Öztürk ve Karaboğa, 2008; Karaboğa ve Akay, 2007; Banerjee, 2012).

4.2 Arıların Yiyecek Arama Davranışları

Yapay arı koloni algoritması doğada arıların var olan yiyecek arama davranışları incelenerek modellenmiş bir yapay zeka optimizasyon algoritmasıdır. Doğada var olan koloni sistemleri göz önüne alındığında, sistemlerin genel işleyişinde çevreden bilgi toplamak ve bu bilgiye göre davranışlar sergilemek vardır.


Doğal bir arı kolonisinde yiyecek bulmak için yapılacak işler o iş için görevlendirilmiş arılar tarafından yapılmaktadır. Arılar sergiledikleri bu iş bölümünde merkezi bir otorite olmaksızın hareket ederler ve kendi kendilerine organize olabilme özelliğine sahiptirler (Karaboğa, 2011). Tereshko'nun reaktif difüzyon denkleminde bağlı olarak ortak zekânın ortaya çıkmasını sağlayan minimal yiyecek arama modelinde üç temel ana bileşen vardır. Bunlar yiyecek kaynakları, görevli işçi arılar ve görevsiz işçi arılar sıralanabilir. Bu minimal model, yiyecek kaynağına yönelme ve yiyecek kaynağını bırakma şeklinde iki şekilde çalışmaktadır (Tereshko, 2000).

Arılar ilk safhada nektar veya polen bulmak amacı ile yiyecek kaynaklarına yönelirler. Yiyecek kaynağının değeri, yuvaya yakınlığı, nektar kalitesi, çeşidi gibi birçok etkene bağlıdır. Buna rağmen basitlik bakımından sadece kaynağın zenginliği tek bir ölçüt olarak kullanılabilir (Karaboğa, 2011).

Görevli işçi arılar, daha önceden bulunmuş kaynaklara ait nektarların kovana getirilmesinde görevlidirler. Bu arılar aynı zamanda gittikleri kaynağın öznelik bilgilerini (kalite, yer bilgisi vb.) kovanda bekleyen diğer arılarla paylaşırlar (Karaboğa, 2011).

Görevsiz işçi arılar nektar toplanabilecek kaynak arayışı içerisinde olan arılar olarak tanımlanmaktadır. Görevsiz işçi arılar iki türde bulunabilirler. Bunlardan ilki içsel bir dürtüye bağlı olarak kaynak arayışı içerisinde bulunan kâşif arılar, diğeri ise görevli işçi arıları izleyerek kaynaklar hakkında gelen bilgileri değerlendirip kaynaklara yönelen gözcü arılardır. Kâşif arıların sayısının kovandaki diğer arıların sayısına oranı % 5-10 arasındadır (Karaboğa, 2011).

Arıların arasındaki bilgi paylaşımı ortak toplanan bilginin oluşumunda önemli bir husustur. Tüm arı kovanlarında ortak alanlar bulunmaktadır. Arı kolonileri için bunlardan en önemlisi dans alanıdır. Yiyecek kaynağının tüm bilgileri dans alanında diğer arılara aktarılmaktadır. Bir arı dans ederken diğer arılar ona antenleri ile dokunarak yiyecek kaynağı hakkında getirilen bilgileri toplarlar. Kovanda bulunan gözcü arılar aldıkları kaynak bilgisi nektara yönelirler ve bilgiyi getiren arılar tekrar yeni kaynak aramaya başlarlar. Arılar gıda kaynaklarından en uygun olanını kendi karar verme mekanizmaları ve nektarın kalitesine göre karar verirler. Şekil 4.1’de verilen örnek arama şeklinde iki adet keşfedilmemiş yiyecek kaynağı (A ve B) verilmiştir.



Şekil 4.1: Arılarda yiyecek arama döngüsü (Karaboğa, 2011).

Bu durumda olan bir arı için aşağıdaki olası seçenekler meydana çıkmaktadır (Karaboğa, 2011);

- Kaşif arı olabilir ve içgüdüsel veya dış etmenlere bağlı olarak yiyecek kaynağı aramaya başlayabilir (Şekil 4.1’de S ile gösterilmektedir).
- Yiyecek kaynağının bilgilerini içeren dansı izleyen bir gözcü arı olabilir ve izlediği dansla tasvir edilen kaynağa yönelebilir (Şekil 4.1’de R ile gösterilmektedir). Bir kaynak bulunduktan sonra arı imkanları çerçevesinde bu kaynağın bilgilerini hafızasına alır ve nektar toplamaya başlar. Bu durumda arı artık görevli bir arı haline gelmiş olur. İşçi arılar kaynaktan nektarı aldıktan sonra yuvaya döner ve bunu yiyecek depolayıcılara aktarır. Nektarı aktardıktan sonra arı için şu üç seçenek ortaya çıkar (Teodorovi’c vd., 2011);
- Gittiği kaynağı bırakarak bağımsız izleyici arı olabilir (Şekil 4.1’de UF ile gösterilmektedir),
- Gittiği kaynağa dönmeden önce dansını sergiler ve kovandaki diğer arıları o kaynağa yönlendirir (Şekil 4.1’de EF1 ile gösterilmektedir),
- Diğer arılara haber vermeksizin kaynağa yönelebilir (Şekil 4.1’de EF2 ile gösterilmektedir).

4.3 Yapay Arı Koloni Algoritmasının İşleyişi

Arıların yiyecek arama davranışı modellenerek geliştirilen en güncel algoritma YAKA'dır (Akyol ve Alataş, 2012). Bu algoritmada temel alınan modelde basitlik amacı ile bazı kabuller yapılmıştır. Bunlardan ilki her bir kaynağın sadece bir görevli arı tarafından alınıyor olmasıdır. Bu da görevli arı sayısının yiyecek kaynağı sayısına eşit olduğunu kabul etmektedir. Bir diğer kabulde ise işçi arıların sayısı gözcü arıların sayısına eşit olduğudur. Bunların farklı olması da beklenebilir fakat ilk kabuller optimizasyon adına bu yöndedir. Genel anlamda, YAKA'da, en kaliteli ve fazla nektara sahip kaynağın yerinin bulunması çalışılarak uzaydaki çözümlerden problemin minimum veya maksimumunu veren noktayı bulmak amaçlanmaktadır.

YAKA modeline ait süreç adımları aşağıdaki gibi sıralanabilir (Karaboğa, 2011):

1. Kâşif arıların çevrede rastgele aramalar yaparak yiyecek aramaya başlarlar,
2. Yiyecek kaynakları tespit edildikten sonra kâşif arılar artık görevli bir arı haline gelirler ve kaynaktan kovana nektar taşımaya başlarlar. Yuvaya nektarı getiren görevli arı topladığı nektarı boşalttıktan sonra yuvadakilere dans sergileyerek nektarın bilgisini aktarabilir veya bulduğu kaynağa geri dönebilir. Eğer kaynak tükendi ise tekrar kâşif arı halini alır ve yeni kaynak arayışına başlar.
3. Kovanda bekleyen gözcü arılar ise kovana kâşif arılar tarafından dans sergilenerek bilgisi iletilen kaynaklara yönelip nektar toplamaya başlarlar.

YAKA'nın temel birimleri aşağıdaki gibi açıklanabilir (Akay, 2009);

Adım 1: Başlangıç yiyecek kaynaklarının üretilmesi.

REPEAT

Adım 2: Görevli arıların yiyecek kaynaklarına yönelmesi

Adım 3: Olasılıksal seleksiyonda kullanılacak değerlerin görevli arılardan gelen bilgiye göre hesaplanması

Adım 4: Gözcü arıların gelen olasılık değerlerine göre yiyecek kaynaklarına yönelmesi

Adım 5: Tüklenen kaynakların bırakılması ve kâşif arı üretimi.

UNTIL (Çevrim sayısı=Maksimum çevrim sayısı)

4.3.1 Yiyecek kaynaklarının üretilmesi

YAKA arama uzayında çözümlere karşılık gelen rastgele yiyecek kaynaklarının yerlerinin belirlenmesi ile işe başlamaktadır. Rastgele yiyecek kaynağının yerinin

üretilmesi süreci her bir parametrenin alt ve üst sınırları arasında rastgele değer üreterek gerçekleşir (Karaboğa ve Baştürk, 2008). Denklem 4.1’de bu süreç formüle edilmiştir.

$$X_{ij} = X_j^{\min} + \text{rand}(0,1) \cdot (X_j^{\max} - X_j^{\min}) \quad (4.1)$$

Yukarıdaki formülde $i=1, \dots, SN$, $j=1 \dots D$. SN yiyecek kaynağı sayısı ve D ise optimize edilecek parametre sayısını ifade etmektedir. $X_j^{\min}$, j parametre sayısının alt sınırını ifade ederken, $X_j^{\max}$ j parametre sayısının üst sınırını ifade etmektedir.

4.3.2 Görevli arıların yiyecek kaynağı bölgelerine gönderilmesi

Her bir kaynağın bir görevli arısı vardır. Bu nedenle yiyecek kaynağı sayısı ile görevli arı sayısı birbirine eşit olmaktadır. İşçi arı üzerinde çalıştığı mevcut yiyecek kaynağının yakınında yeni bir yiyecek kaynağı belirler ve bunun nektar kalitesini ölçer. Eğer yeni kaynak eski kaynaktan daha kaliteli ise yeni kaynağa yönelir. Fakat eski kaynaktan daha az kaliteli ise eski kaynağından nektar toplamaya devam eder. Yeni kaynağın eski kaynak komşuluğunda belirlenmesinde eşitlik 4.2 kullanılır (Karaboğa, 2011).

$$V_{ij} = X_{ij} + \emptyset_{ij}(X_{ij} - X_{kj}) \quad (4.2)$$

Denklemde X_{ij} ve X_{kj} , farklı eski iki yiyecek kaynağının porsiyonları ve çözümlerini temsil etmektedir. Bunlar arasındaki fark azaldıkça X_{ij} parametresindeki değişim miktarı da azalacaktır. Burada j parametresi $[1,D]$ aralığında rastgele üretilen bir tamsayıdır. D , daha önce belirtildiği gibi optimize edilecek parametre sayısıdır. Denklemde $\emptyset_{ij}$ $[-1, 1]$ arasında rastgele bir değerdir. Burada üretilen V_{ij} daha önceden belli olan parametre sınırlarını aşıyorsa, j . parametreye ait olan alt ve üst sınırlara ötelenir (Denklem 4.3).

$$V_{ij} = \begin{cases} X_j^{\min} & , V_{ij} < X_j^{\min} \\ V_{ij} & , X_j^{\min} \leq V_{ij} \leq X_j^{\max} \\ X_j^{\max} & , V_{ij} > X_j^{\max} \end{cases} \quad (4.3)$$

Sınırlar içerisinde üretilen V_i parametre vektörü yeni kaynağı temsil etmekte ve bunun kalitesi hesaplanarak bir uygunluk değeri atanmaktadır. Uygunluk değerinin atanmasına ilişkin eşitlik Denklem 4.4’de verilmiştir (Teodorovi’c vd., 2012).

$$\text{fitness}_i = \begin{cases} 1/(1 + f_i) & , f_i \geq 0 \\ 1 + \text{abs}(f_i) & , f_i < 0 \end{cases} \quad (4.4)$$

Denklem 4.4’de gösterilen f_i , V_i kaynağının yani çözümün maliyet değeridir. X_i ile V_i arasındaki nektar miktarına göre bir aç gözlü seleksiyon işlemi uygulanır. Yeni bulunan çözüm daha iyi ise görevli arı hafızasındaki eski kaynağı silerek bu yeni kaynağı hafızaya alır. Aksi takdirde eski kaynağa gitmeye devam eder.

4.3.3 Gözcü arıların olasılık değerlerini hesaplaması

Tüm görevli arılar gittikleri kaynaklardan aldıkları bilgileri yuvada bulunan gözcü arılara dans aracılığı ile iletirler. Gözcü arılar bu bilgilerden faydalanarak yiyecek kaynaklarının nektar miktarları ile orantılı olacak şekilde bir bölge seçimi yaparlar. Denklem 4.5’de bir kaynağın uygunluk değerinin tüm kaynakların uygunluk değerine oranı, o kaynağın seçilme olasılığını göstermektedir (Akay, 2009).

$$p_i = \frac{fitness_i}{\sum_{j=1}^{SN} fitness_j} \quad (4.5)$$

Burada $fitness_i$, i . kaynağın kalitesini, SN görevli arı sayısını ifade etmektedir.

4.3.4 Gözcü arıların yiyecek kaynağı bölgelerini seçmesi

Eşitlik 4.5’de hesaplanan p_i değerine göre arılar yiyecek bölgelerinin uygunluk değerlerini hesaplarlar. Bu hesaplamada $[0,1]$ arasında rastgele bir sayı üretilerek p_i değerinin üretilen sayıdan büyük veya küçük olması kontrol edilir. Eğer rastgele değerden büyükse görevli arılar gibi gözcü arılarda bu kaynak için yeni bir çözüm üretir. Çözüm eski çözümden daha iyi ise bu kaynak seçilir ve kullanılır.

4.3.5 Tükenen kaynağı bırakma ve yeni kaynaklar bulunması

Görevli ve gözcü arılar arama işlemini tamamladıktan sonra komşuluklardan faydalanılarak yeni kaynak arayışlarına başlanır ve uygunluk değerleri düşük kaynaklar bırakılır.

4.4 YAKA’nın Temel Özellikleri ve Literatürde Kullanımı

YAKA’nın temel özellikleri aşağıdaki gibi sıralanabilir (Karaboğa, 2011);

- Oldukça basit ve esnektir,
- Gerçek arıların davranışlarını oldukça benzer bir şekilde optimize eder,
- Sürü zekasına dayalı çalışan bir algoritmadır,

- Nümerik problemler için geliştirilmiş olmasına rağmen ayırık problemler için de kullanılabilir bir yapıdadır,
- Oldukça az kontrol parametresine sahiptir,
- Arılar tarafından gerçekleştirilen küresel ve bölgesel araştırma kabiliyetlerine sahip, iki araştırmayı da dengeli şekilde yürütebilen bir yapıdadır.

YAKA'nın kontrol parametreleri ile ilgili literatürde tavsiye edilen değerler, koloni büyüklüğü için genellikle 20-50 arasında, limit değer için ise parametre sayısı (D) ile koloni büyüklüğü (SN) nün çarpımı civarında bir değer önerilmektedir (Karaboğa, 2011).

Yapay arı koloni algoritması literatürde birçok problemin çözümünde kullanılmıştır (Karaboğa vd., 2014). Karaboğa ve Akay (2009) tarafından yapılan çalışmada YAKA, genetik algoritma, parçacık sürü optimizasyonu, diferansiyel gelişim algoritması ve evrim stratejileri ile karşılaştırılmıştır. Çalışmada YAKA'nın daha az kontrol parametresi avantajı ile birlikte diğer karşılaştırılan algoritmalarından daha iyi veya benzer sonuçlar ürettiği görülmüştür. Gao ve Liu (2011), çalışmalarında YAKA'yı geliştirilmiş bir biçimde kullanarak global optimizasyon problemlerinde kullanmayı hedeflemişlerdir. Yapılan çalışmada YAKA diferansiyel gelişim değerleri kullanılarak geliştirilmiş ve optimizasyon problemlerinde kullanılmıştır. Çalışma sonucunda YAKA 13 adet mevcut algoritma ile karşılaştırılmış ve daha iyi çözümler bulduğu saptanmıştır. Mala vd. (2009) çalışmalarında YAKA kullanarak deney dizisi optimizasyonu uygulamış ve Karınca Koloni Optimizasyonu ile karşılaştırmışlardır. Sonuçlarda YAKA'nın bazı avantajları olduğu ortaya çıkmıştır. Karaboğa ve Öztürk (2009) makine öğrenmede yaygın olarak kullanılan farklı veri setlerini sınıflandırmak için ileri beslemeli yapay sinir ağları üzerinde YAKA'yı kullanmışlardır. Kurban ve Beşdok (2009) çalışmalarında radyal tabanlı yapay sinir ağlarını eğitmek adına YAKA'yı kullanmışlardır. Rao ve Pawar (2009) elektrik kablolarında elektrik deşarjının modellenmesi ve optimizasyonunda YAKA kullanmışlardır. Sönmez (2011) inşaat mühendisliğinde kafes yapılarının tasarımı için YAKA'da bazı modifikasyonlar uygulanarak problem çözümüne gidilmiştir. Wu vd. (2011) fonksiyonel akış modeline dayalı protein-protein etkileşimleri ağının kümelemek için YAKA kullanarak yeni bir yöntem yaklaşımı sunmuştur.

4.5 YAKA ile Uydu Görüntülerinin Sınıflandırılması


Uydu görüntülerinin sınıflandırılması işleminde birçok yöntem kullanılmaktadır. Ancak, YAKA ile uydu görüntülerinin sınıflandırılması ile ilgili sınırlı sayıda çalışma bulunmaktadır. Banerjee (2012) çalışmasında YAKA kullanarak uydu görüntülerinden özellik çıkarımı yapmış ve bunları sınıflandırma için kullanmıştır. Çalışmasının sonucunda YAKA ile çıkardığı özelliklerden yaptığı sınıflandırma sonuçlarını en kısa mesafe, en çok benzerlik, fuzzy sınıflandırıcısı, biyocoğrafya temelli optimizasyon, üyelik hesaplama gibi yöntemlerle karşılaştırmış ve YAKA'nın en iyi sonuçları verdiğini gözlemlemiştir. Atasever vd. (2011) çalışmalarında YAKA'yı uydu görüntülerinin kontrolsüz sınıflandırması için kullanmışlardır. YAKA sonuçlarını K-means ve Fuzzy C-Means algoritmaları ile karşılaştırmışlar ve YAKA'nın diğerlerine göre kontrolsüz sınıflandırmada daha iyi sonuçlar verdiğini göstermişlerdir. Ma vd. (2011) sentetik açıklıklı radar verilerin segmentasyonu için YAKA'nın kullanımını irdelemiş ve farklı iterasyon ve limit denemeleri yaparak en uygun işlemi bulmaya çalışmışlardır. Deriche ve Fizazi (2015) YAKA'yı meteorolojik uydu görüntülerinin kontrolsüz sınıflandırılması için kullanmışlardır. Bu işlemi yapabilmek için en uygun koloni ve iterasyon sayısı arayışına yönlenmişlerdir. YAKA'nın matematiksel metot olarak sınıflandırma işlemlerindeki performansını incelemişlerdir. Jayanth vd. (2015) YAKA'yı uydu görüntülerinin sınıflandırılması için özellik çıkarımında kullanmıştır. Elde edilen sonuçları en çok benzerlik algoritması ve yapay sinir ağları ile karşılaştırmış ve YAKA'nın daha iyi sonuçlar verdiğini ortaya koymuştur.

5. ÇALIŞMA ALANI VE UYGULAMA

5.1 Çalışma Alanı Seçimi

Türkiye, çay tarım alanlarının genişliği bakımından, dünyada üretici ülkeler arasında 7. sırada, kuru çay üretimi yönünden de 5. sırada, yıllık kişi başına tüketim bakımından ise 4. sırada yer almaktadır (Özden, 2009). Türkiye’de çay üretimi genel itibarı ile Karadeniz Bölgesinde yapılmaktadır. Özellikle Rize ili, gerek arazi yapısı gerekse iklim koşulları yönünden çay üretimine elverişli bir bölge olduğundan çalışma alanı olarak seçilmiştir. Rize ili Türkiye’nin kuzeyinde Karadeniz Bölgesinde yaklaşık 3920 km²’lik alana sahiptir. Arazi örtüsü açısından değerlendirildiğinde ilin yaklaşık % 75’i çay ve orman alanlarından oluşmaktadır. Geri kalan alanlar ise mera, açık toprak, yerleşim yerleri ve diğer tarım alanlarıdır. İl alanının yaklaşık % 70’i, eğimi % 40 üstündeki alanlardan oluşmaktadır (TÜBİTAK, 2009).

Çalışma alanı olarak kullanılacak olan Rize iline ait belirli bölgelerde, uydu görüntüleri temin edilecek alanlar belirlenmiştir. QuickBird uydu görüntüsü temini için seçilen alan Rize ili Ardeşen ilçesinde takribi 10 km²’lik bir alan olarak belirlenmiştir. Arazi örtüsü genellikle çay ve ağaçlık alanlardan oluşan bu bölge kısmen yapılaşma ve sulak alanları da bünyesinde barındırmaktadır. Uygulamada kullanılacak bir diğer alan ise, WorldView-2 uydu verisi temin edilen Rize il merkezi ve Güneysu ilçesi arasında kalan yaklaşık 8 km²’lik, genellikle çay ve yeşil bitki örtüsüne sahiptir. Her iki çalışma alanında da arazi yapısı oldukça engebeli ve normal tarımdan çok, çay gibi kümelenmiş ve dar alanlarda yetismeye müsait bitki örtüsünden meydana gelmektedir. Şekil 5.1’de uygulama yapılması amacı ile Rize iline ait bir harita ve çalışma yapılacak alanlara ait kısımlar gösterilmiştir.




Şekil 5.1 : Rize ili haritası ve seçilen çalışma alanları.


5.2 Kullanılan Veri ve Yazılımlar

Uygulamada, Rize ilinde seçilen alanlara ait sınıflandırma işlemlerini sağlayabilmek için 23.06.2013 tarihli, 4 bantlı, multispektral 2.4 m ve pankromatik 0.60 m yersel çözünürlüğe sahip Quickbird uydu verisi kullanılmıştır. Bunun yanı sıra diğer çalışma alanı için ise 26.12.2014 tarihli, 8 bantlı, multispektral 2 m ve pankromatik 0.5 m. yersel çözünürlüğe sahip WorldView-2 uydu verisinden yararlanılmıştır. Şekil 5.2 ve 5.3 'te Quickbird ve Worldview-2 uydusuna ait görüntüler verilmiştir.

Bu tez çalışmasında uydu görüntülerinin kesilmesi, indis değerlerinin oluşturulması ve eğitim alanlarının belirlenmesi için ERDAS Imagine yazılımı, YAKA ve YSA kodlarının düzenlenmesi için ise MATLAB yazılımı kullanılmıştır. Hata matrislerinin oluşturulması ve doğruluk analizlerinin yapılması için ArcGIS 10.1 programı kullanılmıştır.



Şekil 5.2: WorldView-2 uydu görüntüsü ve bant özellikleri.



Şekil 5.3: QuickBird uydu görüntüsü ve bant özellikleri.

5.3 Genel Bilgiler

Bu tez çalışmasının temel amacı, YAKA'nın çok yüksek çözünürlüklü uydu görüntülerinin sınıflandırılmasındaki performansının irdelenmesidir. Bu amaçla YAKA, çok yüksek çözünürlüklü Quickbird ve Worldview-2 uydu görüntülerinde uygulanmıştır. YAKA sonuçlarının performansı ise en çok benzerlik ve yapay sinir ağları yöntemleri ile karşılaştırılmıştır. İşlemlerin başında mevcut yazılım kodlarının düzenlenmesi ve sınıflandırma işlemi için uygun ve uygulanabilir hale getirilmesi gerekmektedir. Daha sonra sınıflandırması yapılacak görüntüler üzerinden eğitim ve test verilerinin seçilmesi işlemi yapılmıştır. Veriler sırasıyla en çok benzerlik, yapay sinir ağları ve yapay arı koloni algoritması ile optimize edilmiş yapay sinir ağları ile sınıflandırılmıştır. Bu çalışmada asıl amaç YAKA'nın uydu görüntülerinin sınıflandırılmasındaki performansını incelemektir. Bu çalışmada YSA'nın seçilmesinin nedeni birçok çalışmada klasik sınıflandırma yöntemlerinden daha yüksek sonuçlar vermesidir (Heerman ve Khazenie, 1992; Hara vd., 1995; Hernandez vd., 1992; Özkan, 2001).

5.4 YAKA Kodlarının MATLAB Yazılımında Düzenlenmesi

Yapay arı koloni algoritmasının kaynak kodları Karaboğa tarafından internet üzerinde kullanıma açık olarak bulunmaktadır (URL-3). Kodlar MATLAB, Java, C, C++ gibi programlama dillerinde ayrı ayrı kodlanmış olarak internet sitesi üzerinden erişime açıktır. Bu tez çalışması için YAKA'nın MATLAB programlama dilinde yazılmış kodları kullanılmıştır. Bu kaynak kodlar ilk aşamada analiz edilmiş ve koddaki elemanların hangi işlevleri sağladığı incelenmiştir. YAKA temel kaynak kodları ilk aşamada kontrolsüz sınıflandırma için ikinci aşamada ise YSA'nın optimize edilmesi için kontrollü sınıflandırmada kullanılmıştır. YAKA temel kodları içerisine yazılan bir amaç fonksiyonunu optimize etmek için dizayn edilmiş bir yapıya sahiptir. Bu nedenle sınıflandırma yapmak için YAKA temel kodlarına ve kod elemanlarına uygun bir biçimde amaç fonksiyonları kontrollü ve kontrolsüz sınıflandırmalar için ayrı ayrı yazılmıştır. Kontrolsüz sınıflandırma işleminde sınıf merkezlerine yakınlık optimize edilirken kontrollü sınıflandırma işleminde YSA'nın girdi katmanındaki ağırlık ve bias değerleri optimize edilmek istenmiştir. İşlem süreci içerisinde YSA ile girdi katmanında verilen değerler YAKA ile sürekli güncellenerek çıktı katmanına optimize edilmiş olarak geçmiş ve sınıflandırılmış en

doğru görüntüye ulaşmak hedeflenmiştir. Matlab yazılımında “imread” komutu kullanılarak “.tiff” uzantılı olarak yazılıma tanıtılan uydu görüntüleri “imtool” veya “imshow” komutları yardımı ile MATLAB ekranına tekrar çağırılabilir. Yazılıma aktarılan görüntü, farklı matris işlemlerine tabii tutularak amaç fonksiyonu için kullanılabilir hale getirilmiştir. Denklem 5.1’de işlem içerisinde kullanılan YSA eğitim aşaması gösterilmektedir.

$$\text{net} = \text{newff}(\text{minmax}(\text{alanlar}'), [\text{nn } b], \{\text{'tansig' 'tansig'}\}, \text{'trainlm'}) \quad (5.1)$$

Burada “newff” ifadesi YSA ile eğitilecek verinin ve transfer fonksiyonlarının girildiği adımdır. “alanlar” ile ifade edilen kısım eğitim verilerini, “b” ile ifade edilen kısım ise sınıf sayısını göstermektedir. “nn” ifadesi ise ağda kullanılacak yapay nöron sayısını ifade etmektedir. “tansig” ifadesi tanjant sigmoid transfer fonksiyonunu ifade ederken, “trainlm” ifadesi Levenberg-Marquardt geri yayılım algoritmasını ifade etmektedir.

5.5 Eğitim ve Test Alanlarının Belirlenmesi

Uydu görüntülerinin kontrollü sınıflandırılması işleminde ana esas eğitim ve test verilerinin kullanıcı tarafından belirlenmesi işlemidir. Bu çalışmada WorldView-2 ve Quickbird uydu görüntüleri için ayrı ayrı eğitim ve test verileri seçilmiştir. Çalışma alanına bağlı olarak her bir sınıflandırma işlemi için (YSA, YAKA, EÇB) aynı eğitim ve test verileri kullanılmıştır. Ayrıca test verileri Rize iline yapılan arazi çalışmasında arazi üzerinden toplanan örnek veriler ile sağlanmıştır. Aynı veri setlerinin kullanılmasındaki amaç bütün sınıflandırma işlemlerinin eşit veriler ile yapılmasını sağlamaktır. Quickbird ve WorldView-2 uydu verileri için oluşturulan 5 sınıf Çizelge 5.1’de verilmiştir.

Çizelge 5.1: Quickbird ve Worldview-2 uydu verileri için arazi örtüsü sınıfları.

<u>Sınıf Etiketleri</u>
Ağaçlık
Çay
Dere/Deniz
Toprak
Yerleşim

5.6 Sınıflandırma İşlemleri

Yapılan uygulamada yapay sinir ağları, yapay arı koloni algoritması ve en çok benzerlik yöntemleri kullanılarak Worldview-2 ve Quickbird uydu verileri kontrollü ve kontrolsüz olarak sınıflandırılmıştır. Kontrolsüz sınıflandırmada YAKA ve ISODATA yöntemleri, kontrollü sınıflandırma işlemlerinde ise YAKA, YSA ve EÇB yöntemleri kullanılmıştır. Sınıflandırma işlemlerinde öncelikle eğitim ve test alanları belirlenmiş ve MATLAB yazılımı üzerinde bu verilerin kullanılabilmesi için gerekli kodlar yazılmış ve düzenlemeler yapılmıştır.

5.6.1 Kontrolsüz sınıflandırma işlemleri

Uygulama sırasında ilk olarak eğitim veri setleri kullanılmadan yapılan kontrolsüz sınıflandırma işlemleri gerçekleştirilmiştir. Bu işlemler için sınıf sayısı 5 olarak belirlenmiştir. Nitekim diğer bütün sınıflandırma işlemlerinde de bu 5 sınıf kullanılacaktır. Daha önceki bölümlerde bahsedildiği üzere bu yöntemler kullanıcı tarafından belirtilen sınıf sayısına göre kendi içerisindeki hesaplamalar sonucu görüntüyü o sınıf sayısına ayırır. Burada ilk işlem olarak YAKA ile kontrolsüz sınıflandırma ardından ise ISODATA yöntemi ile kontrolsüz sınıflandırma işlemleri gerçekleştirilmiş ve bütün uygulamalarda kullanılan test verileri ile test edilerek doğrulukları araştırılmıştır.

5.6.1.1 ISODATA kontrolsüz sınıflandırma

Literatürde sınıflandırma doğruluğu açısından diğer yöntemlere göre daha kabul edilebilir sonuçlar veren ISODATA (Iterative Self Organising Data Analysis Techniques) yöntemi en çok kullanılan kontrolsüz sınıflandırma yöntemidir (Csillag, 2000; Reis, 2003; Ekercin, 2007). Yöntem mantık olarak verilen belirli sınıf sayısına göre görüntü üzerindeki piksellerin sınıflara ayrılması esasına dayanmaktadır. Bu süreçte Öklid veya L1 uzaklığı denilen uzaklık hesaplama yöntemleri kullanılmaktadır. Uzaklığı hesaplanan yöntem algoritmanın hesapladığı hangi sınıf merkezine uygunsa o sınıfa atanır ve işlem bu şekilde iterasyon adedince devam eder. ISODATA yöntemi ile elde edilen yapılan kontrolsüz sınıflandırma sonucunda elde doğruluk ve kappa değerleri Çizelge 5.2’de verilmiştir.

Çizelge 5.2 : ISODATA yöntemi ile sınıflandırma doğruluk değerleri.

WorldView-2		Quickbird	
Genel Doğruluk (%)	Kappa Değeri	Genel Doğruluk (%)	Kappa Değeri
62	0.54	80	0.73


Çizelge 5.3’de Worldview-2 uydu görüntüsünün ISODATA yöntemi ile kontrolsüz sınıflandırılması sonucu, Çizelge 5.4’de ise Quickbird uydu görüntüsünün ISODATA yöntemi ile kontrolsüz sınıflandırılması sonucunda oluşan hata matrisi verilmiştir. Şekil 5.4 ve Şekil 5.5’de ISODATA kontrolsüz sınıflandırma sonucu oluşan tematik haritalar verilmiştir.

Çizelge 5.3: Worldview-2 uydu görüntüsü için ISODATA yöntemi ile sınıflandırma hata matrisi (ÜD: Üretici Doğruluğu-KD: Kullanıcı Doğruluğu).


Sınıf Etiketi	Ağaçlık	Çay	Dere	Toprak	Yerleşim	KD
Ağaçlık	633	33	4	0	14	0.93
Çay	3	833	0	59	31	0.90
Dere	451	468	281	0	14	0.23
Toprak	88	92	0	430	120	0.59
Yerleşim	264	45	0	72	704	0.65
ÜD	0.44	0.57	0.99	0.77	0.80	

Çizelge 5.4: Quickbird uydu görüntüsü için ISODATA yöntemi ile sınıflandırma hata matrisi.

Sınıf Etiketi	Ağaçlık	Çay	Dere	Toprak	Yerleşim	KD
Ağaçlık	846	220	0	2	0	0.87
Çay	166	861	0	0	0	0.61
Deniz	0	0	396	0	0	0.52
Toprak	0	0	0	119	0	0.83
Yerleşim	0	8	17	209	245	0.17
ÜD	0.29	0.59	1.00	0.68	0.45	



Şekil 5.4: Quickbird uydu görüntüsü ISODATA kontrolsüz sınıflandırma sonuç haritası.



Şekil 5.5: Worldview-2 uydu görüntüsü ISODATA kontrolsüz sınıflandırma sonuç haritası.

5.6.1.2 YAKA ile kontrolsüz sınıflandırma

Kontrolsüz sınıflandırma işlemi kullanıcıdan bağımsız olarak eğitim seti girilmeksizin yapılan sınıflandırma işlemidir. Bu sınıflandırma işlemi yapmak için MATLAB yazılımı üzerinde YAKA'ya entegre edilmek üzere bir kod yazılmıştır. Bu kodlar, uydu görüntüsünü matris şeklinde yazılıma yüklenip, verilen sınıf sayısına uygun olarak sınıf merkezlerine uzaklıklar belirlenerek en yakın olasılık ve uzaklık değerindeki pikseli o sınıfa atamak üzere çalışmaktadır. Sınıflandırma işleminin yapılması için YAKA parametreleri uydu görüntülerine uygun biçimde düzenlenmiştir. Worldview-2 uydu görüntüsü için popülasyon değeri bant sayısı ve oluşturulacak sınıf sayısı çarpımı ($D=8*5=40$) olarak belirlenmiştir. YAKA'nın kontrol parametreleri ile ilgili literatürde tavsiye edilen değerler, koloni büyüklüğü için genellikle 20-50 arasında, limit değeri için ise parametre sayısı (D) ile koloni büyüklüğü (SN) nün çarpımı civarında bir değer önerilmektedir (Karaboğa, 2011). YAKA ile kontrolsüz sınıflandırma işlemi yapılırken koloni büyüklüğü değeri 20 olarak, limit değeri ise 2000 olarak belirlenmiştir. Bu değerler çerçevesinde algoritmanın maksimum çevrim sayısı 3000 olarak belirlenmiş ve algoritma 3 kez art arda çalıştırılmıştır. Quickbird uydu görüntüsü için ise $D=20$, $SN=20$, $Limit=1000$ ve itreasyon değeri ise 1200 olarak alınmıştır. Kontrolsüz sınıflandırma işleminde eğitim verisi girilmemesinden ve uydu görüntülerindeki veri yoğunluğundan dolayı işlem zaman alabilmektedir. Çizelge 5.5'de YAKA ile yapılan kontrolsüz sınıflandırma işlemlerine ait doğruluk ve kappa değerleri verilmiştir. Çizelge 5.6 ve Çizelge 5.7'de YAKA ile kontrolsüz sınıflandırmaya ilişkin hata matrisleri verilmiştir. Bu matrislere göre doğruluk analizleri yapılmış ve kappa değerleri elde edilmiştir. Şekil 5.6 ve Şekil 5.7'de YAKA ile yapılan kontrolsüz sınıflandırma sonucunda oluşan tematik haritalar verilmiştir.

Çizelge 5.5: YAKA ile kontrolsüz sınıflandırma sonucu doğruluk değerleri.


WorldView-2		Quickbird	
Genel Doğruluk (%)	Kappa Değeri	Genel Doğruluk (%)	Kappa Değeri
68	0.57	65	0.52

Çizelge 5.6: Worldview-2 uydu görüntüsü için YAKA ile kontrolsüz sınıflandırma hata matrisi (ÜD: Üretici Doğruluğu-KD: Kullanıcı Doğruluğu).


Sınıf Etiketi	Ağaçlık	Çay	Dere	Toprak	Yerleşim	KD
Ağaçlık	897	377	2	70	36	0.65
Çay	132	741	0	354	16	0.60
Dere	0	0	279	0	16	0.95
Toprak	75	38	3	63	9	0.33
Yerleşim	0	0	1	0	469	1.00
ÜD	0.81	0.64	0.98	0.13	0.86	

Çizelge 5.7: Quickbird uydu görüntüsü için YAKA ile kontrolsüz sınıflandırma hata matrisi.

Sınıf Etiketi	Ağaçlık	Çay	Deniz	Toprak	Yerleşim	KD
Ağaçlık	543	287	0	0	0	0.65
Çay	400	663	0	0	0	0.62
Deniz	0	0	209	0	0	1.00
Toprak	SINIFLANDIRILAMAMIŞ					
Yerleşim	0	0	0	244	342	0.58
ÜD	0.58	0.70	1.00	0.00	1.00	



Şekil 5.6: Quickbird uydu görüntüsü YAKA kontrolsüz sınıflandırma sonuç haritası.



Şekil 5.7: Worldview-2 uydu görüntüsü YAKA kontrolsüz sınıflandırma sonuç haritası.

Kontrolsüz sınıflandırma işlemleri sonucunda elde edilen değerlerden de anlaşılacağı üzere çalışma bölgesinin bitki örtüsü yoğunluğundan kaynaklanan sebeplerden dolayı çay ve ağaçlık sınıflarında karışmalar meydana gelmiştir. Bu, bölge için beklenen bir durum olmasına rağmen sınıflandırma doğruluklarını doğrudan etkileyen bir sebep olmuştur. Worldview-2 uydu görüntüsü için YAKA kontrolsüz sınıflandırma işleminde çay alanın üretici doğruluğu % 64 çıkarken Quickbird uydu görüntüsü için bu doğruluk değeri % 70 olmuştur. Fakat ağaçlık sınıfında ise bu durum Quickbird uydu görüntüsünde % 58 çıkarken Worldview-2 uydu görüntüsünde % 81 değerini almıştır. Bununla birlikte Quickbird uydu görüntüsü için YAKA kontrolsüz sınıflandırma işleminde toprak sınıfı tamamen yerleşim sınıfına karışmış ve sınıflandırılamamıştır. Bunun sebebinin işlem sırasındaki verilen iterasyon sayısı ve popülasyon sayısı olduğu düşünülmektedir. Fakat iterasyon sayısı ve popülasyon çok yüksek tutulduğunda bu işlem bir hayli zaman almaktadır. Bant sayısının düşürülmesi veya iterasyon sayısının çok yüksek performanslı bir bilgisayarda yükseltilmesi durumunda bu sorunun ortadan kalkacağı düşünülmektedir.

5.6.2 Kontrollü sınıflandırma işlemleri

Uygulamanın bu bölümünde YAKA, YSA ve EÇB yöntemleri kullanılarak uydu görüntüleri kontrollü olarak sınıflandırılmıştır. Her bir uydu görüntüsü için eğitim ve test veri setleri belirlenmiş ve sonuçların bu veri setlerinden bağımsız olması için çalışma alanına göre aynı görüntü için her yöntemde aynı veri seti kullanılmıştır. Sınıflandırmalar için her bir görüntüde 5 arazi örtüsü sınıfı belirlenmiştir. Worldview2 uydu görüntüsü için belirlenen sınıflar ağaçlık, çay, dere, toprak ve yerleşim olurken Quickbird uydu görüntüsü için dere sınıfı yerine deniz sınıfı kullanılmıştır. Worldview-2 uydu görüntüsünün sınıflandırma işlemine öncelikle 8 bantın tamamı dahil edilmiştir. Daha sonrasında sınıflandırma doğruluklarının artırılması amacıyla WV2 bant kombinasyonlarından yararlanılmıştır. Bu kombinasyonlardan tüm sınıflandırma yöntemlerinde en yüksek doğruluk değerlerine ulaşan bantlar kullanılmıştır. Bunlardan “coastal” ve “yellow” bantlar çıkarılarak elde edilen kombinasyonlarda en yüksek doğruluk değerlerine ulaşılmıştır. Ayrıca, Worldview-2 uydu görüntüsünde mevsimden ve yüksek eğimden dolayı meydana gelen gölgelenme sorununu en aza indirmek amacıyla yüksek doğruluk veren bant kombinasyonuna ayrıca NDVI eklenerek sınıflandırma işlemi yapılmıştır. Bu görüntü artık 6 bant ve ayrıca NDVI verisini de bir bant olarak kullanıldığı toplam 7 bantlı bir görüntü halini almıştır. Bu bölümde Quickbird uydu görüntülerinin ve 8 bantlı Worldview-2 görüntülerinin yanında 6 bant ve NDVI bantlarına sahip Worldview-2 görüntüleri de sınıflandırılacaktır.

5.6.2.1 En çok benzerlik algoritması ile sınıflandırma

En çok benzerlik algoritması (EÇB) literatürde yaygın kullanıma sahip istatistiksel bir sınıflandırma algoritmasıdır (Kayman, 2015). EÇB yöntemi ile yapılan sınıflandırma işlemi MATLAB programında kullanılan hazır bir kod seti ile yapılmıştır. Sınıflandırma işleminde Worldview-2 ve Quickbird uydu görüntüleri için oluşturulan eğitim ve veri setleri ile sınıflandırma işlemi gerçekleştirilmiş ve ArcGIS 10.1 programı ile hata matrisi oluşturulmuştur. Hata matrisi üzerinde yapılan işlemler sonucunda doğruluk değeri ve kappa değerlerine ulaşılmıştır.

İlk sınıflandırma işlemleri 8 bant Worldview-2 uydu görüntüsüne uygulanarak, % 72 genel doğruluk değerine ulaşılmıştır. Quickbird uydu görüntüsü için ise genel doğruluk değeri % 83 olarak hesaplanmıştır. Çizelge 5.8’de EÇB algoritması ile

yapılan sınıflandırma sonuçlarına göre hesaplanan genel doğruluk ve kappa değerleri gösterilmiştir.

İkinci sınıflandırma işlemi ise Worldview-2 uydu görüntüsünün 6 bandına (RGB, RE, NIR1 ve NIR2) ilave NDVI eklenerek yapılmıştır. Çizelge 5.8’de sınıflandırılmış verinin doğruluk ve kappa değerleri verilmiştir. Çizelge 5.9’da ise Worldview-2 uydu görüntüsü için en çok benzerlik algoritması ile yapılan sınıflandırma sonucunda oluşturulan hata matrisi, Çizelge 5.10’da ise Quickbird uydu görüntüsü için hesaplanan hata matrisi verilmiştir. Çizelge 5.11’de 6 bant+NDVI değerlerine sahip Worldview-2 uydu görüntüsü için sınıflandırma hata matrisi verilmiştir. Şekil 5.8, Şekil 5.9 ve Şekil 5.10’da EÇB yöntemi ile sınıflandırma sonucunda oluşan tematik haritalar gösterilmektedir.

Çizelge 5.8: En çok benzerlik algoritması ile sınıflandırma sonucu doğruluk değerleri.

Uydu Görüntüleri	Genel Doğruluk (%)	Kappa Değerleri
Worldview-2 (8 Bant)	74	0.65
Worldview-2 (6 Bant+NDVI)	79	0.73
Quickbird	83	0.76

Çizelge 5.9: Worldview-2 uydu görüntüsü için EÇB algoritması ile sınıflandırma hata matrisi (ÜD: Üretici Doğruluğu-KD: Kullanıcı Doğruluğu).


Sınıf Etiketi	Ağaçlık	Çay	Dere	Toprak	Yerleşim	KD
Ağaçlık	1187	485	0	107	116	0.63
Çay	235	986	0	103	0	0.74
Dere	0	0	180	0	0	1.00
Toprak	4	0	25	334	91	0.74
Yerleşim	13	0	80	17	676	0.86
ÜD	0.82	0.67	0.63	0.59	0.77	

Çizelge 5.10: Quickbird uydu görüntüsü için EÇB algoritması ile sınıflandırma hata matrisi.


Sınıf Etiketi	Ağaçlık	Çay	Deniz	Toprak	Yerleşim	KD
Ağaçlık	2246	611	0	0	0	0.79
Çay	294	1434	0	0	0	0.83
Deniz	0	0	1043	0	0	1.00
Toprak	0	0	115	207	23	0.60
Yerleşim	0	0	0	46	432	0.90
ÜD	0.88	0.70	0.90	0.82	0.95	

Çizelge 5.11: Worldview-2 6 Bant+NDVI görüntüsü için EÇB algoritması ile sınıflandırma hata matrisi.


Sınıf Etiketi	Ağaçlık	Çay	Deniz	Toprak	Yerleşim	KD
Ağaçlık	1283	368	0	50	62	0.73
Çay	98	962	0	39	0	0.88
Dere	0	0	190	0	0	1.00
Toprak	0	0	0	466	47	0.91
Yerleşim	58	141	95	6	774	0.72
ÜD	0.89	0.65	0.67	0.83	0.88	



Şekil 5.8: Quickbird uydu görüntüsü EÇB yöntemi ile sınıflandırma sonuç haritası.



Şekil 5.9: Worldview-2 uydu görüntüsü EÇB yöntemi ile sınıflandırma sonuç haritası.



Şekil 5.10: Worldview-2 6 Bant+NDVI uydu görüntüsü EÇB yöntemi ile sınıflandırma sonuç haritası.

Quickbird uydu görüntüsünün sınıflandırılması sonucu çay alanlarının üretici doğruluk oranı %70 ve kullanıcı doğruluğu da %83 olmuştur. Ağaçlık alanlarda ise sırasıyla %88 ve %79 olarak elde edilmiştir. EÇB sınıflandırıcı çay ve ağaçlık alanları birbirinden yeterli derecede ayıramadığından üretici doğruluk oranları %80'in altında kalmıştır.

WV2 uydu görüntüsünün sınıflandırılması sonucu ağaç (%82) ve çay tarım alanlarına (%67) ait üretici doğruluklarına ve sırasıyla da %63 ve %74 kullanıcı doğruluklarına ulaşılmıştır. Bu husus WV2'nin tüm bantlarının kullanılması durumunda ağaç ve çay alanlarının birbirine oldukça fazla karıştığının bir göstergesi olmuştur. Bu karışıklığın en önemli sebebi WV2 uydu görüntüsündeki gölgelik alanlardır. Bu gölgelerin oluşmasındaki temel etkenler ise, topografyadan kaynaklı yüksek eğim ile uydu görüntüsünün nadir ve güneş açısidir. Bu durumu minimize etmek amacıyla 6 banda NDVI eklenerek tekrar sınıflandırma işlemi yapılmıştır. Bu sınıflandırma sonucu; ağaç (%89) ve çay tarım alanlarına (%65) ait üretici doğruluklarına ve sırasıyla da %73 ve %88 kullanıcı doğrulukları elde edilmiştir. 8 bant Worldview-2 uydu görüntüsünde EÇB algoritması ile sınıflandırma sonucu genel doğruluk % 72 çıkarken 6 bant ve NDVI'lı görüntüde ise bu değer % 79'a ulaşarak doğrulukların arttığı görülmüştür.

5.6.2.2 YSA ile Sınıflandırma

YSA ile görüntülerin sınıflandırılması işleminde çok katmanlı perseptron ağ yapısından ileri beslemeli geri yayılma öğrenme algoritması kullanılmıştır. Ağın eğitilmesi aşamasında Levenberg-Marquardt geri yayımlı eğitim fonksiyonuna başvurulmuştur. Bu fonksiyon ağ içerisindeki ağırlık ve bias değerlerinin optimizasyonu ile görevli fonksiyondur (URL-4). Ağın giriş katmanındaki değerleri çıkış katmanına taşınması için kullanılan transfer fonksiyonlarından biri olan hiperbolik tanjant sigmoid transfer fonksiyonu bant değerlerinden sınıf değerlerine geçiş aşamasında kullanılmıştır. Ağın yapısında giriş katmanı, kullanılan her bir banda karşılık yapay bir nöron gelecek biçimde tasarlanmıştır. Ağ yapısında giriş katmanı için Worldview-2 uydu görüntüsünde 8 banda karşılık 20 yapay nöron, 4 bant içeren Quickbird uydu görüntüsü için ise yine 20 adet yapay nöron tesis edilmiştir. Çıkış katmanında her bir sınıf için bir nöron olacak şekilde her iki uydu görüntüsü için de 5 adet (ağaçlık, çay, deniz/dere, toprak, yerleşim) yapay nöron tesis edilmiştir. Çok

katmanlı perseptron ağ yapısında oluşturulacak gizli katmanlar ağın işleyişi ve genelleştirme açısından önem arz etmektedir ve bu değerlerin optimum olarak belirlenmesi gerekmektedir (Çölkesen, 2009). Kullanılacak gizli ağıdaki optimum sayı için herhangi bir kesin yaklaşım bulunamadığından bu sayısı sınıflandırma sonuçları dikkate alınarak deneme-yanılma yöntemi ile elde edilmiştir. Genel ağ yapısında her iki görüntü için de 20 adet gizli katman düğüm noktası kullanılmıştır. Ağ yapısı Worldview-2 uydu görüntüsü için 8-20-5 şeklinde, Quickbird uydu görüntüsü için ise 4-20-5 şeklinde oluşturulmuştur. 6 bant ve NDVI değerlerine sahip Worldview-2 uydu görüntüsü için ise ağ yapısı 7-20-5 şeklindedir. YSA yapısı için işlemlerde yapılan denemeler sonucunda maksimum epok (iterasyon) sayısı 100 olarak belirlenmiş ve işlemler bu iterasyon üzerinden yapılmıştır. Yapılan işlemler MATLAB yazılımının YSA araç kutusu aracılığı ile yapılmış, oluşturulan kodlar görüntü sınıflandırma için uygun hale getirilmiştir.

YSA ile yapılan sınıflandırmalar sonucunda hesaplanan genel doğruluk değerleri ve kappa değerleri Çizelge 5.12’de verilmiştir. Çizelge 5.13, Çizelge 5.14 ve Çizelge 5.15’de bu sınıflandırmalar sonucunda hesaplanan hata matrisleri verilmiştir. Şekil 5.11, Şekil 5.12 ve Şekil 5.13’de YSA yöntemi ile sınıflandırma sonucunda oluşan tematik haritalar gösterilmektedir.

Çizelge 5.12: YSA ile sınıflandırma sonucu doğruluk değerleri.

Uydu Görüntüleri	Genel Doğruluk (%)	Kappa Değerleri
Worldview-2 (8 Bant)	74	0.65
Worldview-2 (6 Bant+NDVI)	82	0.76
Quickbird	91	0.87

Çizelge 5.13: Worldview-2 uydu görüntüsü için YSA sınıflandırma hata matrisi (ÜD: Üretici Doğruluğu-KD: Kullanıcı Doğruluğu).


Sınıf Etiketi	Ağaçlık	Çay	Dere	Toprak	Yerleşim	KD
Ağaçlık	1266	448	0	128	21	0.68
Çay	146	963	0	277	11	0.69
Dere	0	0	275	0	3	0.99
Toprak	0	0	0	156	85	0.65
Yerleşim	27	60	10	0	763	0.89
ÜD	0.88	0.65	0.96	0.28	0.86	

Çizelge 5.14: Quickbird uydu görüntüsü için YSA sınıflandırma hata matrisi.


Sınıf Etiketi	Ağaçlık	Çay	Deniz	Toprak	Yerleşim	KD
Ağaçlık	1985	31	0	0	0	0.98
Çay	556	2014	0	0	0	0.78
Deniz	0	0	1157	0	1	1.00
Toprak	1	0	0	241	0	1.00
Yerleşim	0	0	0	16	455	0.97
ÜD	0.78	0.98	1.00	0.94	1.00	

Çizelge 5.15: Worldview-2 6 Bant+NDVI görüntüsü için YSA sınıflandırma hata matrisi.


Sınıf Etiketi	Ağaçlık	Çay	Deniz	Toprak	Yerleşim	KD
Ağaçlık	1337	473	0	99	18	0.69
Çay	88	978	0	25	0	0.90
Dere	0	0	184	0	0	1.00
Toprak	1	0	0	432	0	1.00
Yerleşim	13	20	101	5	865	0.86
ÜD	0.93	0.66	0.65	0.77	0.98	



Şekil 5.11 : Quickbird uydu görüntüsü YSA yöntemi ile sınıflandırma sonuç haritası.



Şekil 5.12: Worldview-2 uydu görüntüsü YSA yöntemi ile sınıflandırma sonuç haritası.



Şekil 5.13: Worldview-2 6 Bant+NDVI uydu görüntüsü YSA yöntemi ile sınıflandırma sonuç haritası.

YSA ile yapılan sınıflandırma işlemleri sonucunda Worldview-2 uydu görüntüsünün genel doğruluğu % 71 çıkarken Quickbird uydu görüntüsünde bu doğruluk %91 olmuştur. Arada oluşan bu farkın nedeni, 5.6.2.1 bölümünde açıklandığı gibi Worldview-2 uydu görüntüsündeki gölgelik alanlardır. 8 bantlı Worldview-2 uydu görüntüsünde ağaçlık sınıfının üretici doğruluğu % 88 çıkarken 6 bantlı ve NDVI değerlerine sahip görüntü için bu değer % 93'e ulaşmıştır. Quickbird uydu görüntüsünde ağaçlık sınıfı % 78 üretici doğruluğu ile sınıflandırılırken çay sınıfının üretici doğruluk değeri % 98'e ulaşmıştır. Bu sonuç kullanıcı doğruluğu değerlerini de göz önüne alarak çay ve ağaçlık sınıflarında EÇB yöntemine göre daha az olsa da yine de belli oranda karışmaların meydana geldiğini göstermektedir.

5.6.2.3 YAKA ile kontrollü sınıflandırma

YAKA ile uydu görüntülerinin sınıflandırılması iki aşamada gerçekleştirilmiştir. İlk aşamada Karaboğa (2011) tarafından internet üzerinde hazır bulunan kodların sınıflandırmada kullanılması amacıyla düzenlenmiştir. Bu süreç içerisinde YAKA için bir amaç fonksiyonu geliştirilmiştir. YAKA burada YSA'nın eğitilmesi ile işleme başlamaktadır. YSA'nın ağırlık ve bias değerleri optimize edilerek en doğru sonuca ulaşmaya çalışılmıştır. Oluşturulan kodlar YAKA'ya entegre edilerek sınıflandırma işlemleri yapılmıştır. YAKA parametrelerin seçimi için birçok deneme yapılmıştır. YAKA'nın temel değerleri olan koloni büyüklüğü ve limit değeri için optimum sayıya ulaşılması gerekmektedir. Bu amaçla yapılan yüzlerce deneme sonrasında, koloni büyüklüğü 20 olarak girilen uygulamada limit değeri, koloni büyüklüğü ve kodlar içerisinde hesaplanan ağırlık ve bias değerlerinin toplamının çarpımına yakın bir değer olarak seçilmiştir. Algoritmanın maksimum çevrim sayısı ise limit değerinden çok fazla olmaması gerekmektedir. Bu doğrultuda YAKA ile sınıflandırma yapmak için yaklaşık 4000 limit değeri ve 4200 maksimum çevrim sayısı kullanılmıştır. Oluşturulan kodlar, ilk işlem olarak uydu görüntüsünü ve eğitim verilerini okumaktadır. Daha sonra bu eğitim değerleri YSA giriş katmanına gönderilip gizli katman ve giriş katmanı arasında kalan ağırlık ve bias değerlerini optimize etmektedir. Optimize edilen değerler çıkış katmanına direkt transfer edilerek sonuç ürünler ortaya çıkmıştır.

YAKA ile yapılan sınıflandırma sonucunda hesaplanan genel doğruluk ve kappa değerleri Çizelge 5.16’de verilmiştir. Ayrıca Çizelge 5.17, Çizelge 5.18 ve Çizelge 5.19’da uydu görüntülerinin sınıflandırılması sonucunda oluşturulan hata matrisleri gösterilmektedir. Şekil 5.14, Şekil 5.15 ve Şekil 5.16’da YAKA ile kontrollü sınıflandırma sonucunda oluşan tematik haritalar gösterilmektedir.

Çizelge 5.16: YAKA ile kontrollü sınıflandırma sonucu doğruluk değerleri.

Uydu Görüntüleri	Genel Doğruluk (%)	Kappa Değerleri
Worldview-2 (8 Bant)	79	0.71
Worldview-2 (6 Bant+NDVI)	82	0.76
Quickbird	93	0.90

Çizelge 5.17: Worldview-2 uydu görüntüsü YAKA ile sınıflandırma hata matrisi (ÜD: Üretici Doğruluğu-KD: Kullanıcı Doğruluğu).


Sınıf Etiketi	Ağaçlık	Çay	Dere	Toprak	Yerleşim	KD
Ağaçlık	1116	73	2	70	36	0.86
Çay	285	1301	0	350	16	0.67
Dere	0	0	279	0	16	0.95
Toprak	38	97	3	141	9	0.49
Yerleşim	0	0	1	0	806	1.00
ÜD	0.78	0.88	0.98	0.25	0.91	

Çizelge 5.18: Quickbird uydu görüntüsü YAKA ile sınıflandırma hata matrisi.


Sınıf Etiketi	Ağaçlık	Çay	Dere	Toprak	Yerleşim	KD
Ağaçlık	2242	91	0	0	16	0.95
Çay	271	1954	0	22	0	0.87
Deniz	0	0	1157	0	0	1.00
Toprak	2	0	0	232	5	0.97
Yerleşim	27	0	0	3	435	0.94
ÜD	0.88	0.96	1.00	0.90	0.95	

Çizelge 5.19: Worldview-2 6 Bant+NDVI görüntüsü için YAKA kontrollü sınıflandırma hata matrisi.


Sınıf Etiketi	Ağaçlık	Çay	Dere	Toprak	Yerleşim	KD
Ağaçlık	1322	351	0	38	32	0.76
Çay	92	1092	0	28	0	0.90
Dere	0	1	211	0	0	1.00
Toprak	17	10	0	387	2	0.93
Yerleşim	8	17	74	108	849	0.80
ÜD	0.92	0.74	0.74	0.69	0.96	



Şekil 5.14: Quickbird uydu görüntüsü YAKA kontrollü sınıflandırma yöntemi ile sınıflandırma sonuç haritası.



Şekil 5.15: Worldview-2 uydu görüntüsü YAKA kontrollü sınıflandırma yöntemi ile sınıflandırma sonuç haritası.




Şekil 5.16: Worldview-2 6 Bant+NDVI uydu görüntüsü YAKA kontrollü sınıflandırma sonuç haritası.

YAKA ile tüm bantların kullanılmasıyla WV2 uydu görüntüsü kontrollü sınıflandırma sonucunda çay alanlarında %88 ve ağaçlık sınıfında %78 oranlarında üretici ve sırasıyla %67 ve %86 kullanıcı doğruluklarına ulaşılmıştır. Bu görüntüdeki gölgelik sorunundan dolayı yerleşim (%91 ÜD) ve toprak alanların (%25 ÜD) oldukça yüksek oranda karıştığı görülmüştür. YAKA'nın 6 bant+NDVI WV2 görüntüsünün sınıflandırılması sonucu, çay alanlarında %74 ve ağaçlık sınıfında %92 oranlarında üretici ve sırasıyla %90 ve %76 kullanıcı doğruluklarına ulaşılmıştır. Bu durumda 6 bant+NDVI kombinasyonu ile yapılan sınıflandırmalarda doğrulukların arttığı görülmüştür.


YAKA yönteminin Quickbird uydu görüntüsüne uygulanması sonucunda çay alanlarında %96 ve ağaçlık sınıfında % 88 oranlarında üretici ve sırasıyla %87 ve %95 kullanıcı doğruluklarına ulaşılmıştır. Bu sonuçlara göre Quickbird uydu görüntüsünün sınıflandırılmasında YAKA ile elde edilen sonuçlar diğer yöntemlere oranla daha yüksek elde edilmiştir.

5.7 YAKA'nın EÇB ve YSA ile Karşılaştırılması

Bu bölümde YAKA ile elde edilen kontrollü sınıflandırma sonuçları YSA ve EÇB yöntemleri ile karşılaştırılarak, YAKA'nın sınıflandırma performansı değerlendirilmiştir. Şekil 5.17'de tez içerisinde yapılan sınıflandırma işlemlerinden elde edilen genel doğruluk değerleri ve Şekil 5.18'de kappa değerleri karşılaştırılmış ve grafik halinde sergilenmiştir. Verilen grafiklerden de anlaşılacağı üzere YAKA ile görüntü sınıflandırma işlemi genel doğruluk değerleri ve kappa değerlerinin karşılaştırılması sonucunda karşılaştırılan diğer yöntemlere nazaran daha iyi sonuçlar verdiği görülmektedir.




Şekil 5.17: Sınıflandırma yöntemlerine ait genel doğruluk karşılaştırması.




Şekil 5.18: Sınıflandırma yöntemlerine ait kappa değerlerinin karşılaştırılması.

YAKA yönteminin çay tarım alanlarındaki sınıflandırma performansı Şekil 5.19'da gösterilmiştir. Çay sınıfının üretici değerleri 8 bantlı Worldview-2 uydu görüntüleri için diğer yöntemlerden yüksek değerlere ulaşırken Quickbird uydu görüntüsünde YSA yönteminden düşük fakat EÇB yönteminden yüksek çıkmıştır. Kullanıcı doğrulukları karşılaştırıldığında ise Worldview-2 uydu görüntülerinde diğer yöntemlere göre daha düşük doğruluklara ulaşırken Quickbird uydu görüntüsünde EÇB yöntemi ile yaklaşık olarak benzer değerlere ulaşmıştır.



Şekil 5.19: Çay alanlarının üretici ve kullanıcı doğrulukları.

YAKA yönteminin ağaçlık alanlardaki sınıflandırma performansı Şekil 5.20'de gösterilmiştir. Ağaçlık sınıfının üretici değerleri 8 bantlı Worldview-2 uydu görüntüsü için diğer yöntemlerden düşük çıkarken Quickbird uydu görüntüsünde diğerlerinden yüksek çıkmıştır. Kullanıcı doğruluklarında ise Worldview uydu görüntülerinde diğer yöntemlerden daha yüksek çıkarken Quickbird uydu görüntüsü için YSA yönteminden biraz düşük fakat EÇB yönteminden daha yüksek çıkmıştır.



Şekil 5.20: Ağaçlık alanların üretici ve kullanıcı doğrulukları.

6. SONUÇ VE ÖNERİLER

Uzaktan algılama teknolojisi yeni nesil uydular sayesinde geniş alanların yüksek çözünürlüklü görüntülenebilmesi kabiliyetine sahiptir. Sınıflandırma sonucunda elde edilen tematik haritaların ve sınıflara ait bilgilerin güvenilirliği sınıflandırmada kullanılan yöntemler ve elde edilen doğruluklar birbirleri ile doğrudan ilişkilidir. Bu tez çalışmasında Yapay Arı Koloni Algoritması yönteminin genelde arazi örtüsü özelde ise çay tarım alanlarının kontrollü ve kontrolsüz sınıflandırılmasındaki etkisi araştırılmıştır. Bu amaçla çok yüksek çözünürlüklü uydu görüntülerinden Quickbird ve Worldview-2 uydu görüntüleri kullanılmıştır. Uydu görüntüleri çay, ağaçlık, dere/deniz, toprak ve yerleşim olmak üzere 5 sınıf altında sınıflandırılmıştır. YAKA yönteminin sınıflandırma performansı ise En Çok Benzerlik ve Yapay Sinir Ağları yöntemleriyle karşılaştırılmıştır. Tüm yöntemlerin kontrollü ve kontrolsüz sınıflandırma işlemleri ile doğruluk analizlerinde çalışma bölgelerine bağlı olarak aynı eğitim ve aynı test verileri kullanılmıştır.

Bu tez kapsamında uydu görüntülerinin sınıflandırılması amacıyla kullanılan YAKA yöntemi, doğadaki gerçek arıların davranışları izlenilerek ortaya çıkarılmış bir yapay zeka optimizasyon algoritmasıdır. Bu algoritma günümüzde birçok meslek disiplininde problemlerin optimize edilmesi ve en doğru sonuca yaklaşma arzusu ile kullanılmaktadır. Bu çalışmada YAKA'ya MATLAB programında amaç fonksiyonları yazılarak uydu görüntülerinin kontrollü ve kontrolsüz sınıflandırma işlemlerinde kullanılmıştır. YAKA kontrolsüz sınıflandırma işlemi için kendi içerisindeki parametreleri kullanarak ve pikselleri sınıf merkezlerine yönlendirerek sınıflandırma işlemini gerçekleştirmektedir. Bu işlem içerisinde kullanılan limit değerleri ve iterasyon sayıları büyük önem arz etmektedir. Henüz literatürde YAKA için herhangi bir parametre belirleme yöntemi olmadığından bu işlemler deneme-yanılma yöntemi ile yapılmış ve sonuçlara göre en optimum değerler elde edilmiştir. YAKA ile kontrollü sınıflandırma işlemlerinde kullanılan YSA yapısı içerisinde bulunan ağırlık ve bias değerlerinin en optimum değere ulaşması sağlanmış ve sınıflandırma işlemi bu değerler üzerinden yapılmıştır.

YAKA'nın kontrollü sınıflandırma işleminde kullanımı, mevcut bir sınıflandırma yönteminin parametrelerinin optimize edilmesi şeklindedir. Bu yüzden literatürde kullanılan sınıflandırma yöntemlerinden birisi seçilerek eğitim aşamasında devreye sokulup sınıflandırma başında işleme dahil olması sağlanması gerekmektedir. Bu nedenle tez çalışmasında yüksek doğruluk verdiği literatür araştırmaları ile sabit olan YSA yöntemi bu amaçla kullanılmıştır.

YAKA ile yapılan kontrollü sınıflandırma işlemlerinde yaklaşık bütün sınıfların doğruluk değerlerinde bir artış görülmüştür. Sınıflandırmalar sonucunda YAKA ile yapılan kontrollü sınıflandırmada, genel doğruluklar 8 bantlı Worldview-2 uydu görüntüsü için EÇB ve YSA yöntemlerinden %2 daha doğru sonuçlara ulaşılmıştır. YAKA ile Quickbird uydu görüntüsünün sınıflandırılması sonucunda üretilen genel doğruluklar EÇB yönteminden %10 ve YSA yönteminden % 2 daha doğru sonuçlar vermiştir. Worldview-2 uydu görüntüsünün 6 bant+NDVI bant kombinasyonunda YAKA ile yapılan sınıflandırma sonuçlarında ise EÇB yönteminden %4 ve YSA yönteminden %1 daha doğru sonuçlara ulaşılmıştır.

Rize ilinde yaygın tarım ürünü olarak kullanılan çay bitkisinin ayırt edilmesi işlemi, YAKA ile elde edilen sınıflandırma doğrulukları sensörlere ve bant kombinasyonuna göre değişiklik göstermiştir. Çay bitkisi YAKA sınıflandırma yönteminde tüm bant ve 6 bant+NDVI Worldview-2 uydu görüntülerinin sınıflandırılmasında diğer yöntemlere göre daha yüksek doğruluğa (Üretici doğruluğu) ulaşmıştır. Bununla birlikte YAKA kullanıcı doğruluğunda 6 bant+NDVI Worldview-2 uydu görüntüsünde YSA yöntemi ile eşit doğruluklara ulaşmıştır. Özellikle kullanıcı doğruluklarında ise YAKA sınıflandırma yöntemi çay bitkisinde diğer yöntemlere göre daha düşük çıkmıştır.

YAKA ile yapılan kontrollü sınıflandırma işleminde verilen iterasyon sayısı ve YSA kullanımı için verilen yapay nöron sayısı doğruluklar ve sınıflandırma açısından önemlidir. Optimum iterasyon, limit ve nöron sayısına ulaşıldığı takdirde daha yüksek doğruluklara çıkılabileceği öngörülmektedir. YAKA ile görüntü sınıflandırma işleminin dezavantajı ise diğer yöntemlere göre uzun süre almasıdır.

7. KAYNAKLAR

- Akay, B., 2009. Nümerik Optimizasyon Problemlerinde Yapay Arı Koloni Algoritmasının Performans Analizi, Doktora Tezi, Erciyes Üniversitesi Fen Bilimleri Enstitüsü.
- Akyol, S., Alataş B., 2012. Güncel Sürü Zekâsı Optimizasyon Algoritmaları, Nevşehir Üniversitesi Fen Bilimleri Enstitü Dergisi 1 (2012) 36-50.
- Altun, H., Eminoğlu, U., ve Tezekici, B. S., 2010. MLP Yapay Sinir Ağlarında Öğrenme Sürecinin Aktivasyon Fonksiyonu ve İstatiksel Değişim Gösteren Giriş Verilerine Bağımlılığı.
- Atasever, Ü. H., 2011. Uydu Görüntülerinin Sınıflandırılmasında Hızlandırma (Boosting), Destek Vektör Makineleri, Rastgele Orman (Random Forest) Ve Regresyon Ağaçları Yöntemlerinin Kullanılması, Yüksek Lisans Tezi, Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Kayseri.
- Atasever, Ü.H., Özkan, C., Sunar, F., 2011. The Use of Artificial Intelligence Optimization Algorithms in Unsupervised Classification, Remote Sensing and Geoinformation not only for Scientific Cooperation, EARSeL 2011.
- Atkinson, P. M., ve Tatnall, A. R. L. ,1997. Introduction neural networks in remote sensing. International Journal of remote sensing, 18 (4), 699-709.
- Ayhan, E., Karşlı, F., Tunç E., 2003. Uzaktan Algılanmış Görüntülerde Sınıflandırma ve Analiz, Harita Dergisi.
- Banerjee, S., 2012. Image Classification Using Artificial Bee Colony Algorithm, Master of Technology In Computer Technology and Application, Department of Computer Engineering, Delhi Technological University.
- Benediktsson, J. A., Swain, P. H. and Ersoy, O. K., 1990. Neural network approaches versus statistical methods in classification of multisource remote sensing data. I.E.E.E. Transactions on Geoscience and Remote Sensing, 28, 540-552.
- Campbell, J.B., 1996. Introduction to Remote Sensing, Guilford Press, New York, 621 s.
- Csillag, F., Perera, A. ve Wilson, H., 2000. Land Cover Analysis of the Moose River Basin, Forest Ecosystem Science Co-operative, Final Report, Toronto.

- Çölkesen, İ., 2009. Uzaktan Algılamada İleri Sınıflandırma Tekniklerinin Karşılaştırılması ve Analizi, Yüksek Lisans Tezi, Gebze İleri teknoloji Üniversitesi Mühendislik ve Fen Bilimleri Enstitüsü, Gebze.
- Teodorovi'c D., Davidovi'c T, Selmi'c M., 2011. Bee Colony Optimization: The Applications Survey, ACM Transactions on Computational Logic.
- Demuth, H., Beale, M., 1993. Neural network toolbox for use with MATLAB.
- Deriche, R., ve Fizazi, H., 2015. The Artificial Bee Colony Algorithm for Unsupervised Classification of Meteorological Satellite Images. International Journal of Computer Applications, 112 (12).
- Ekercin, S., 2007. "Uzaktan Algılama Ve Coğrafi Bilgi Sistemleri Entegrasyonu İle Tuz Gölü Ve Yakın Çevresinin Zamana Bağlı Değişim Analizi", Doktora Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Erbay, A.Y., 2014. Farklı Özellikleriyle Yeni Nesil Dünya Gözlem Uyduları Ve Kullanım Alanları, NİK İnşaat Tic. Ltd. Şti., İstanbul.
- Gao, W., ve Liu, S., 2011. Improved artificial bee colony algorithm for global optimization. Information Processing Letters, 111 (17), 871-882.
- Hara, Y., Atkins, R. G., Shin, R. T., AHu Kong, J., Yueh, S. H., & Kwok, R., 1995. Application of neural networks for sea ice classification in polarimetric SAR images. Geoscience and Remote Sensing, IEEE Transactions on, 33 (3), 740-748.
- Heermann, P. D., ve Khazenie, N. 1992. Classification of multispectral remote sensing data using a back-propagation neural network. Geoscience and Remote Sensing, IEEE Transactions on, 30 (1), 81-88.
- Hernandez, R., Varfis, A., Kanellopoulos, I.,ve Wilkinson, G. G., 1992. Development of MLP/LVQ hybrid networks for classification of remotely-sensed satellite images. In Proceedings of the 1992 International Conference on Artificial Neural Networks (ICANN-92), Brighton, UK ,Vol. 2, pp. 1193-1196.
- Iounousse, J., Er-Raki, S., El Motassadeq, A., & Chehouani, H., 2015. Using an unsupervised approach of Probabilistic Neural Network (PNN) for land use classification from multitemporal satellite images. Applied Soft Computing, 30, 1-13.
- Kansu, O., 2006. Uzaktan Algılamada Görüntü Sınıflandırma Yöntemleri, Yüksek Lisans Tezi, Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü.
- Karaboğa, D. ve Baştürk, B., 2008. On the performance of artificial bee colony (ABC) algorithm, Applied Soft Computing, 687-697.

- Karaboğa, D. ve Akay, B., 2007. Artificial bee colony (ABC) Algorithm on training artificial neural networks. Proceedings of the 15th IEEE Signal Processing and Communications Applications (SIU '07), pp.
- Karaboğa, D. ve Baştürk, B., 2007. Artificial bee colony (ABC) optimization algorithm for solving constrained optimization problems. Proceedings of the 12th International Fuzzy Systems Association World Congress on Foundations of Fuzzy Logic and Soft Computing (IFSA '07), vol. 4529 of Lecture Notes in Artificial Intelligence, pp. 789–798.
- Karaboğa, D., 2005. An Idea Based On Honey Bee Swarm For Numerical Optimization, TR-06, Erciyes Üniversitesi, Engineering Faculty, Computer Engineering Department.
- Karaboğa, D., 2011. Yapay Zeka Optimizasyon Algoritmaları, Nobel Akademik Yayıncılık, ISBN 978-605-395-434-7, Ankara.
- Karaboğa, D., Görkemli, B., Ozturk, C., & Karaboga, N., 2014. A comprehensive survey: artificial bee colony (ABC) algorithm and applications. Artificial Intelligence Review, 42(1), 21-57.
- Karaboğa, D., Öztürk C., 2009. Neural networks training by artificial bee colony algorithm on pattern classification. Neural Netw World 19 (3):279–292.
- Karaboğa, D., ve Akay, B., 2009. A comparative study of artificial bee colony algorithm. Applied Mathematics and Computation, 214 (1), 108-132.
- Kavzoğlu, T. ve Çölkesen, İ., 2011. “Uzaktan Algılama Teknolojileri ve Uygulama Alanları”, Türkiye’de Sürdürülebilir Arazi Yönetimi Çalıştayı, Okan Üniversitesi, İstanbul.
- Kavzoğlu, T., Reis S., 2008. Performance Analysis of Maximum Likelihood and Artificial Neural Network Classifiers for Training Sets with Mixed Pixels, GIScience & Remote Sensing, 45, 330-342.
- 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, Nottingham University, UK.
- Kavzoğlu, T., ve Çölkesen, İ., 2010. Destek vektör makineleri ile uydu görüntülerinin sınıflandırılmasında kernel fonksiyonlarının etkilerinin incelenmesi. Harita Dergisi, 144 (7), 73-82.
- Kayman, Ö., 2015. Spektral indekslerin arazi örtüsü/kullanımı sınıflandırmasına etkisi: İstanbul, Beylikdüzü ilçesi, arazi kullanımı değişimi, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü.
- Key, J., Maslanik, J. A., Schweiger, A. J., 1989. Classification of merged AVHRR and SMMR Arctic data with neural networks, Photogrammetric Engineering & Remote Sensing, 55, 1331-1338.

- Kurban, T., ve Beşdok, E., 2009. A comparison of RBF neural network training algorithms for inertial sensor based terrain classification. *Sensors*, 9 (8), 6312-6329.
- Lee, J., Weger, R. C., Sengupta, S. K. ve Welch, R. M., 1990. A neural network approach to cloud classification, *I.E.E.E. Transactions on Geoscience and Remote Sensing*, 28, 84-855.
- Lee, S., Ryu, J. H., Won, J. S., ve Park, H. J., 2004. Determination and application of the weights for landslide susceptibility mapping using an artificial neural network. *Engineering Geology*, 71 (3), 289-302.
- Liu, X., Li, X., Liu, L., He, J., ve Ai, B., 2008. An innovative method to classify remote-sensing images using ant colony optimization. *Geoscience and Remote Sensing, IEEE Transactions on*, 46(12), 4198-4208.
- Lillesand, T.M., Kiefer, R.W., Chipman, J.W., 2007. *Remote Sensing and Image Interpretation 6th Edition*, John Wiley & Sons Pres. New York.
- Ma, M., Liang, J., Guo, M., Fan, Y., & Yin, Y., 2011. SAR image segmentation based on Artificial Bee Colony algorithm. *Applied Soft Computing*, 11 (8), 5205-5214.
- Mala DJ, Kamalapriya M, Shobana R, Mohan V., 2009. A non-pheromone based intelligent swarm optimization technique in software test suite optimization. *IAMA: 2009 international conference on intelligent agent and multi-agent systems*, IEEE Madras Section; IEEE Computer Society, Madras Chapter; Computer Society of India Div II; Council of Science & Industrial Research; Govt India, Department of Information Technology, pp 188–192.
- Marchisio, G., 2013. European Space Imaging Partner Meetings, Münih.
- Mather, P.M., 1987. *Computer processing of remote-sensed images*. John Wiley and Sons Ltd.
- Miller, D.M, Kaminsky, E.J., Rana S., 1995. Neural Network Classification of Remote-Sensing Data, *Computers & Geosciences* Vol. 21, No. 3, pp. 377-386.
- Ndehedehe, C., Ekpa, A., Simeon, O., Nse, O., 2013. Understanding the Neural Network Technique for Classification of Remote Sensing Data Sets. *New York Science Journal* 2013; 6 (8): 26-33. (ISSN: 1554-0200).
- Orhan, O., 2014. Konya Kapalı Havzası’nda Uzaktan Algılama Ve Cbs Teknolojileri ile İklim Değişikliği Ve Kuraklık Analizi, Yüksek Lisans Tezi, Aksaray Üniversitesi Fen Bilimleri Enstitüsü, Harita Mühendisliği A.B.D.
- Özden, V.D., 2009. “Türkiye Siyah Çay Sektör Raporu” Avrupa İşletmeler Ağı-Karadeniz.

- Özen, M., 2012. Uzaktan algılama da Piksel ve Nesne-Tabanlı Sınıflandırma, Sınıflandırma Sonuçlarının Değerlendirilmesi, Doğruluk Analizlerinin Yapılması ve CBS Ortamına Aktarımı, Bülent Ecevit Üniversitesi Jeodezi ve Fotogrametri Mühendisliği Anabilim Dalı JDF 821 no' lu Ders Sunumu, Zonguldak.
- Özkan, C., 2001. Uydu Görüntü Verisinin Yapay Sinir Ağları ile Sınıflandırılması, Doktora Tezi, İTÜ Fen Bilimleri Enstitüsü, İstanbul.
- Öztürk, C. ve Karaboğa, D., 2008. "Classification by neural networks and clustering with artificial bee colony (ABC) algorithm," in Proceedings of the 6th International Symposium on Intelligent and Manufacturing Systems, Features, Strategies and Innovation, Sakarya, Turkey.
- Reis, S., 2003. "Çevresel Planlamalara Altlık Bir Coğrafi Bilgi Sistemi Tasarımı ve Uygulaması: Trabzon İl Bilgi Sistemi(TİBİS) Modeli", Doktora Tezi, Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü, Trabzon.
- Schaap, M. G., Leij, F. J., ve van Genuchten, M. T., 1998. Neural network analysis for hierarchical prediction of soil hydraulic properties. Soil Science Society of America Journal, 62 (4), 847-855.
- Sevim, Ö., 2013. Yapay Arı Koloni Algoritması Kullanılarak 3 Boyutlu Çelik Yapıların Optimum Tasarımı, Yüksek Lisans Tezi, Aksaray Üniversitesi Fen Bilimleri Enstitüsü, İnşaat Mühendisliği Anabilim Dalı.
- Strahler, A. H., 1980. The use of prior probabilities in maximum likelihood classification of remotely sensed data, Remote Sens. Environ., vol. 10, no. 2, pp. 135–163.
- Tereshko, V., 2000. Reaction-Diffusion Model of a Honey Bee Colony's Foraging Behaviour, 6th International Conference on Parallel Problem Solving from Nature, 807-816, 3-540-41056-2, Springer-Verlag, London, UK.
- Torrecilla, J. S., Laura Otero, ve P. D. Sanz, 2004. A neural network approach for thermal/pressure food processing. Journal of Food Engineering 62.1 89-95.
- TUBİTAK, 2009. Rize İline (TR904) Ait Heyelan Risk Bölgeleri ve Uygun Yerleşim Alanlarının Coğrafi Bilgi Teknolojileri İle Belirlenmesi (Proje Yürütücüsü: Yrd. Doç. Selçuk REİS), 106Y018 nolu 1001 Bilimsel ve Teknolojik Araştırma Projesi, Ankara, 151s.
- URL-1 <<https://www.digitalglobe.com/sites/default/files/QuickBird-DS-QB-Prod.pdf>>, alındığı tarih 20.05.2015.

URL-2 < <https://www.digitalglobe.com/about-us/content-collection>>, alındığı tarih 20.05.2015.

URL-3 <<http://mf.erciyes.edu.tr/abc/>>, alındığı tarih 10.01.2015.

URL-4 < <http://www.mathworks.com/help/nnet/ref/trainlm.html>>, alındığı tarih 01.06.2015.

Uzaktan Algılama Dokümanı, 2002. İşlem Şirketler Gurubu, Ankara

Wilkinson, G., 1996. A review of current issues in the integration of GIS and remote sensing data,” *Int. J. Geogr. Inf. Sci.*, vol. 10, no. 1, pp. 85–101.

Zou, W., Zhu, Y., Chen, H., ve Sui, X., 2010. A Clustering Approach Using Cooperative Artificial Bee Colony Algorithm’, *Discrete Dynamics in Nature and Society* Volume 2010, Article ID 459796.

Kohonen, T., (1998). The self-organizing map. *Neurocomputing*, 21 (1), 1-6.

ÖZGEÇMİŞ

Adı ve Soyadı : Ahmet Tarık TORUN

Doğum Tarihi ve Yeri: 1990/Malatya

E-posta adresi : ahmettarik.torun@gmail.com

EĞİTİM BİLGİLERİ (Kurum ve Yıl)

Lisans : Aksaray Üniversitesi Harita Mühendisliği/2012

Yüksek Lisans : Aksaray Üniversitesi Fen Bilimleri Enstitüsü/2015

MESLEKİ DENEYİM VE ÖDÜLLERİ

Ağrı İbrahim Çeçen Üniversitesi ÖYP Araştırma Görevlisi /2013-

Aksaray Üniversitesi 2547/35. Madde Görevlendirme, ÖYP Arş. Gör. / 2013-halen