

**T.C
ERCIYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
HARİTA MÜHENDİSLİĞİ ANABİLİM DALI**

**NESNE VE PİKSEL TABANLI SINIFLANDIRMA
YÖNTEMLERİNİN KARŞILAŞTIRILMASI:
BAQUBAH ŞEHİRİ ÖRNEĞİ**

**Hazırlayan
Mothana AL-KARKHI**

**Danışman
Dr. Öğr Üyesi Tuba KURBAN**

Yüksek Lisans Tezi

**Mart 2019
KAYSERİ**

**T.C
ERCIYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
HARİTA MÜHENDİSLİĞİ ANABİLİM DALI**

**NESNE VE PİKSEL TABANLI SINIFLANDIRMA
YÖNTEMLERİNİN KARŞILAŞTIRILMASI:
BAQUBAH ŞEHİRİ ÖRNEĞİ
(Yüksek Lisans Tezi)**

**Hazırlayan
Mothana AL-KARKHI**

**Danışman
Dr. Öğr Üyesi Tuba KURBAN**

**Mart 2019
KAYSERİ**

BİLİMSEL ETİĞE UYGUNLUK

Bu çalışmadaki tüm bilgilerin, akademik ve etik kurallara uygun bir şekilde elde edildiğini beyan ederim. Aynı zamanda bu kural ve davranışların gerektirdiği gibi, bu çalışmanın özünde olmayan tüm materyal ve sonuçları tam olarak aktardığımı ve referans gösterdiğimi belirtirim.



Mothana AL-KARKHI

YÖNERGEYE UYGUNLUK SAYFASI


“Nesne ve Piksel Tabanlı Sınıflandırma Yöntemlerinin Karşılaştırılması: Baqubah Şehri Örneği” adlı Yüksek lisans tezi, Erciyes Üniversitesi Lisansüstü Tez Önerisi ve Tez Yazma Yönergesi’ne uygun olarak hazırlanmıştır.



Hazırlayan

Mothana AL-KARKHI

Danışman



Dr. Öğretim Üyesi Tuba KURBAN



Harita Mühendisliği ABD Başkanı

Prof. Dr. Abdurrahman EYMEN

Dr. Öğretim Üyesi Tuba KURBAN danışmanlığında **Mothana AL-KARKHI** tarafından hazırlanan **“Nesne ve Piksel Tabanlı Sınıflandırma Yöntemlerinin Karşılaştırılması: Baqubah Şehri Örneği”** adlı bu çalışma, jürimiz tarafından Erciyes Üniversitesi Fen Bilimleri Enstitüsü Harita Mühendisliği Anabilim Dalında Yüksek lisans tezi olarak kabul edilmiştir.

08./03/2019

JÜRİ:

İmza

Danışman : Dr. Öğretim Üyesi Tuba KURBAN



Üye : Dr. Öğretim Üyesi Ahmet Emin KARKINLI



Üye : Dr. Öğretim Üyesi Ümran KÖYLÜ



ONAY:

Bu tezin kabulü, Enstitü Yönetim Kurulunun 19/03/2019 tarih ve 2019/22-08 sayılı kararı ile onaylanmıştır.



Enstitü Müdürü

Prof. Dr. Mehmet AKKURT

TEŞEKKÜR

Yüksek Lisans tez çalışmamda, tüm tezin aşamalarında her türlü desteği veren,(bilgi ve tecrübeleriyle beni yönlendiren) değerli hocam (Dr. Öğr Üyesi) TUBA KURBAN'a, her ihtiyaç duyduğumda, yardımlarıyla çalışmama katkıda bulunan sevgili dostum Hussam Atallah'a, ayrıca bana, her konuda ilgisini ve desteğini hiçbir zaman eksik etmeyen sevgili eşim Marwa Mohammed 'e ve değerli aileme teşekkürlerimi sunarım.

Mothana AL-KARKHI



NESNE VE PİKSEL TABANLI SINIFLANDIRMA YÖNTEMLERİNİN KARŞILAŞTIRILMASI: BAQUBAH ŞEHİRİ ÖRNEĞİ

Mothana AL-KARKHI

**Erciyes Üniversitesi Fen Bilimleri Enstitüsü
Yüksek Lisans Tezi, Mart 2019
Tez Danışmanı: Dr. Öğr Üyesi.TUBA KURBAN**

ÖZET

Uydu görüntüleri, dünya yüzeyi hakkında çok fazla bilgi içermektedir. Bu bilgi, çevresel analiz, kentsel faaliyetler, doğal kaynakların yönetimi ve planlaması gibi çeşitli uygulamalar için çok önemlidir. Bu aşamada, en önemli adım, uydular tarafından elde edilen görüntünün yorumlanabilmesi için sınıflandırma işleminin başarılı bir şekilde yapılması aşamasıdır. Uzaktan algılanan görüntülerin sınıflandırılması, arazi örtüsü ve arazi kullanım bilgilerinin toplanması, değişim analizi gibi adımlar için çok önemli bir yöntemdir. Herhangi bir sınıflandırma işleminin başarısı, kullanılan sınıflandırma yöntemine, parametre seçimine ve eğitim alanı seçimine bağlıdır.

Bu tez çalışmasında, BAQUBAH bölgesi arazi örtüsünün ve kullanım türlerinin belirlenmesi amacıyla, bölgeye ait Landsat 8+ (2017) ve Geo-Eye (2014) görüntüleri piksel tabanlı yapay sinir ağları, destek vektör makineleri ve nesne tabanlı en yakın komşuluk yöntemlerle sınıflandırılmıştır.

Yapılan çalışmalar nesne tabanlı sınıflandırma yaklaşımının genel değerlendirme doğruluğu ve kappa faktörünün değerinin piksel tabanlı yaklaşıma göre daha yüksek ve daha başarılı olduğunu göstermiştir.

Anahtar Kelimeler: Destek Vektör Makineleri, Yapay Sinir Ağları Nesne Tabanlı Sınıflandırma

**Comparison of object and pixel based classification techniques: Example of
Baqubah City
Mothana AL-KARKHI**

**Erciyes University, Faculty of Engineering
M. SC Thesis, March 2019
Thesis Supervisor: Dr. Tuba KURBAN**

ABSTRACT

The satellite image contains a lot of accurate information about the earth's surface. This information is a precious source in various applications in the world, such as environmental quality analysis, urban activities, managing and planning of natural resources. The most crucial step is the classification process for interpreting the image obtained by satellites. Classification of remotely sensed images has been the means of obtaining land cover and land use information. The success of any classification depends on the classification's method, selecting parameters and select training area.

In this thesis, to obtain land cover and land use information of BAQUBAH, pixel based classification methods such as artificial neural networks and support vector machines and an object based k-neighbor classification method are applied to Landsat 8+ (2017) and Geo-Eye (2014) images.

The object based classification is superior to pixel based classification (method of artificial neural network and support vector machines) where its assessment accuracy and kappa factor have been very high.

Keywords: Support Vector Machines, Artificial Neural Network, Object Based Classification

İÇİNDEKİLER

NESNE VE PİKSEL TABANLI SINIFLANDIRMA YÖNTEMLERİNİN KARŞILAŞTIRILMASI: BAQUBAH ŞEHİRİ ÖRNEĞİ

BİLİMSEL ETİĞE UYGUNLUK	i
YÖNERGEYE UYGUNLUK SAYFASI	ii
ONAY	iii
TEŞEKKÜR	iv
ÖZET	v
İÇİNDEKİLER	vii
ŞEKİLLER LİSTESİ	ix
TABLolar LİSTESİ	xi
GİRİŞ	1

1. BÖLÜM

GENEL BİLGİLER VE LİTERATÜR TARAMASI

1.1. Elektromanyetik Enerji ve Işık Kaynağı	3
1.2. Atmosferik Etkiler	5
1.3. Atmosferik Pencereleler ve Nesnelerin İmzası	6
1.4. Uzaktan Algılamada Çözünürlük Kavramı	9
1.4.1. Mekansal Çözünürlük	9
1.4.2. Spektral Çözünürlük	10
1.4.3. Radyometrik Çözünürlük	11
1.4.4. Zamansal Çözünürlük	11
1.5. Uzaktan Algılamada Görüntü Analiz Sistemleri	12
1.5.1. Ön İşlem	13
1.5.2. Görüntü İyileştirme	13
1.6. K -ortalama &PCA	14
1.7. Yapay Sinir Ağları	18
1.8. Destek Vektör Makineleri	21
1.9. Segmantasyon ve Nesne Tabanlı Sınıflandırma.	24
1.10. Optimizasyon Tabanlı Sınıflandırma.	26

2. BÖLÜM

GÖRÜNTÜ SINIFLANDIRMA

2.1. Görüntü Sınıflandırması	27
2.1.1. Kontrolsüz sınıflandırması	28
2.1.1.1. K-Ortalama yöntemi	28
2.2. Kontrollü sınıflandırma	30
2.2.1. Destek Vektör Makineleri	30
2.2.1.1. Doğrusal Ayrılabilen Veriler için DVM	31
2.2.1.2. Doğrusal Ayrılamayan Veriler için DVM	35
2.2.2. Yapay Sinir Ağları ile görüntü sınıflandırması	41
2.3. Nesne tabanlı Görüntü Sınıflandırması	42
2.4. Uzaktan Algılama Uyduları	45
2.4.1. LANDSAT Uydu Sistemi	45
2.4.2. TERRA Uydu Sistemi	46
2.4.3.SPOT Uydu Sistemi.	47

3. BÖLÜM

UYGULAMA VE BULGULAR

3.1. Kullanılan Veri ve Yazılımlar	48
3.2. Yapay Sinir Ağları ile Görüntü Sınıflandırma	49
3.3. Destek Vektör Makineleri ile Görüntü Sınıflandırma	57
3.4.Nesne tabanlı Görüntü Sınıflandırması	67

4. BÖLÜM

SONUÇLAR

KAYNAKLAR	73
ÖZGEÇMİŞ	78

ŞEKİLLER LİSTESİ

Şekil 1.1.	Elektromanyetik dalgalar	4
Şekil 1.2.	Elektromanyetik spektrum ve uzaktan algılamada kullanılan bölgeleri.	4
Şekil 1.3.	Rayleigh saçılması.....	6
Şekil 1.4.	Atmosferik Pencereleler.....	7
Şekil 1.5.	Toprak, bitki ve su için genelleştirilmiş spektral yansıtım grafiği.....	8
Şekil 1.6.	Uzaktan algılama uyduları için anlık görüş alanının açısai ve uzunluk olarak ifadesi.	10
Şekil 1.7.	Konumsal çözünürlük kavramı. (a) 1 metre, (b) 10 metre, (c) 30 metre çözünürlüklü görüntüler.	10
Şekil 1.8.	Zamansal Çözünürlüğü.	12
Şekil 1.9.	Görüntü kontrastı.....	14
Şekil 2.1.	Görüntü sınıflandırmasını gösterir	28
Şekil 2.2.	k-ortalama.....	29
Şekil 2.3.	(a) İki sınıflı bir problem için hiper-düzlemler,2.3 (b) Optimum hiper-düzlem ve destek vektörleri.....	31
Şekil 2.4.	Doğrusal olarak ayrılabilen veri setleri için hiper-düzlemin belirlenmesi	32
Şekil 2.5.	Doğrusal Ayrılabilen Veriler için DVM	32
Şekil 2.6.	Doğrusal Ayrılabilen Veriler için DVM	34
Şekil 2.7.	(a) Doğrusal olarak ayrılamayan veri seti, 2.7 (b) Doğrusal ayrılamayan [3]veri setleri için hiper-düzlemin belirlenmesi.doğrusal olarak ayrılmayan verilerin sorunlarını çözmek için verilerin yüksek boyutlu bir alanda görüntülenmesi gerekir. Bu durumda, (2.7c) 'de gösterildiği gibi hiper düzlemi belirleyebiliriz.....	35
Şekil 2.8.	Doğrusal Ayrılamayan Veriler için DVM.....	36
Şekil 2.9.	Doğrusal Ayrılamayan Veriler için DVM.....	38
Şekil 2.10.	Doğrusal Ayrılamayan Veriler için DVM.....	38
Şekil 2.11.	Doğrusal Ayrılamayan Veriler için DVM.....	40
Şekil 2.12.	Yapay Sinir Ağları	41
Şekil 2.13.	Görüntü segmentasyonu (ölçek 100).....	43
Şekil 2.14.	Görüntü segmentasyonu (ölçek 75).....	44

Şekil 2.15. Görüntü segmentasyonu (ölçek 50).....	44
Şekil 2.16. Görüntü segmentasyonu (ölçek 25).....	45
Şekil 3.1. Sınıflandırmada kullanılan Landsat görüntüsü	49
Şekil 3.2. Sınıflandırmada kullanılan Geo-eye görüntüsü	49
Şekil 3.3. Landsat görüntüsünün YSA ile sınıflandırılması.....	51
Şekil 3.4. Landsat görüntüsünün YSA ile sınıflandırılması.....	53
Şekil 3.5. Geo-eye görüntüsünün YSA ile sınıflandırılması.....	55
Şekil 3.6. Geo-eye görüntüsünün YSA ile sınıflandırılması.....	56
Şekil 3.7. Landsat görüntüsünün DVM ile sınıflandırılması	58
Şekil 3.8. Landsat görüntüsünün DVM ile sınıflandırılması.	60
Şekil 3.9. Landsat görüntüsünün DVM ile sınıflandırılması.	61
Şekil 3.10. Geo-eye görüntüsünün DVM ile sınıflandırılması.	63
Şekil 3.11. Geo-eye görüntüsünün DVM ile sınıflandırılması.	65
Şekil 3.12. Geo-eye görüntüsünün DVM ile sınıflandırılması.	67
Şekil 3.13. Landsat görüntüsünün Nesne tabanlı ile sınıflandırılması	68
Şekil 3.14. GEO-EYE görüntüsünün Nesne tabanlı ile sınıflandırılması	70

TABLOLAR LİSTESİ

Tablo 2.1.	Landsat özellikleri.....	46
Tablo 2.2.	Terra özellikleri.....	47
Tablo 2.3.	Spot özellikleri	47
Tablo 3.1.	Kullanılan uydu görüntüleri ve özellikleri.....	48
Tablo 3.2.	Tüm yöntemde kullanılan parametreler.	72
Tablo 3.3.	Doğruluk matrisi (Landsat görüntüsü).....	50
Tablo 3.4.	Doğruluk matrisi (Landsat görüntüsü).....	52
Tablo 3.5.	Doğruluk matrisi (Geo-eye görüntüsü).....	54
Tablo 3.6.	Doğruluk matrisi (Geo-eye görüntüsü).....	55
Tablo 3.7.	Doğruluk matrisi (Landsat görüntüsü).....	57
Tablo 3.8.	Doğruluk matrisi (Landsat görüntüsü).....	59
Tablo 3.9.	Doğruluk matrisi (Landsat görüntüsü).....	60
Tablo 3.10.	Doğruluk matrisi (Geo-eye görüntüsü).....	62
Tablo 3.11.	Doğruluk matrisi (Geo-eye görüntüsü).....	64
Tablo 3.12.	Doğruluk matrisi (Geo-eye görüntüsü).....	66
Tablo 3.13.	Doğruluk matrisi (Landsat görüntüsü).....	67
Tablo 3.14.	Doğruluk matrisi (GEO-EYE görüntüsü).....	69

GİRİŞ

Çeşitli şekillerde tanımlanmış olan uzaktan algılama; esasen bir nesneye dokunmadan bir şeyler iletmenin sanatı veya bilimidir. Diğer bir ifadeyle uzaktan algılama, bir nesnenin fiziksel verilerinin temassız olarak edinilmesidir. Uzaktan algılama, dünya yüzeyinin uzaktan elektromanyetik kayıtlarının veya görüntülerinin elde edilmesine ve görüntü verilerinin işlenmesi ile ilgili bütün metotları kapsamaktadır. Algılayıcı alanındaki hedef alanlardan elektromanyetik radyasyonu tespit eden ve kaydeden en geniş kapsamlı uzaktan algılama,aracıdır[1]. Uzaktan algılama teknolojisinin önemli uygulamalarından bazıları şunlardır.

1. Çevre değerlendirmesi ve izleme (kentsel büyüme, tehlikeli atıklar) .
2. Küresel değişim algılama ve izleme (atmosferik ozon tükenmesi, ormansızlaşma, küresel ısınma) .
3. Tarım (mahsul durumu, getiri tahmini,toprak erozyonu).
4. Yenilenemez kaynak araştırması (mineraller, petrol, doğalgaz).
5. Yenilenebilir doğal kaynaklar (sulak alanlar, topraklar, ormanlar, okyanuslar).
6. Meteoroloji (atmosfer dinamiği, hava Durumu tahmini).
7. Haritalama (topoğrafya, arazi kullanımı, inşaat mühendisliği).
8. Askeri gözetim ve keşif (stratejik politika, taktik değerlendirme).
9. Haber medyası (illüstrasyonlar, analiz)[2].

Tematik haritalar oluşturularak uydu görüntüleri vasıtasıyla arazi örtüsünün tespit edilmesi yararlı bir uygulamadır. Uzaktan algılama teknolojilerinin bir faydası, değişik uzaysal, radyometrik, mekansal ve zamansal çözünürlükteki görüntüleri kullanma becerisidir. Arazi örtüsü ve sürdürülebilir çevresel değişikliklerin tespiti zamansal çözünürlüğü önemli kılmaktadır. Uydu görüntülerinin sınıflandırılması, arazi örtüsünü tespit etmek amacıyla yaygın bir şekilde kullanılmaktadır. Sayısal görüntü sınıflandırma, pikselleri sınıflara tasnif etme işlemidir. Genel olarak her bir piksel birkaç spectral banttaki değerlerden oluşan tek bir birim olarak ele alınır. Uzaktan

algılanan verilerin benzer piksel gruplarını ilgisel bilgi kategorileri ile ilişkili sınıflara birleştirilebilmektedir. Uzaktan algılamada görüntü iki şekilde sınıflandırılmaktadır (kontrollü ve kontrolsüz sınıflandırma). Kontrolsüz sınıflandırmadan çoğunlukla çalışma alanı ile ilgili birincil bir bilgiye sahip olunmadığında faydalanılır. K-ortalamlar (kontrolsüz sınıflandırma) algoritması daha yaygın kümeleme yöntemlerinden birisidir . Bu yöntemde bilinmeyen her bir noktayı etiketlemek için 'merkeze en kısa mesafe' karar verme kuralı uygulanır. Bu yöntemde benzer özelliklere sahip sınıflar görüntü pikselinin özelliklerinden faydalanılarak işlenmiştir. Kontrollü sınıflandırma ise, bilinen kimliğin örneklerini kullanma süreci olarak tanımlanabilir .Destek Vektör Makineleri(DVM) sınıflar arası ayırımı en verimli şekilde yapmaktadır ve idealist hiper düzlem vasıtasıyla iki veya daha çok sınıf verilerinin sınıflandırılması amacıyla kullanılan kontrollü sınıflandırma yöntemlerinden biridir. DVM, uydu görüntüleri gibi çeşitli sınıfları ve doğrusal olmayan verileri işlevleri aracılığıyla sınıflandırır. Kontrollü sınıflandırma yöntemlerinden bir tanesi de yapay sinir ağıdır. İnsan beynindeki nöronların çalışmasını örnek alan yapay sinir ağları yöntemi görüntüleri sınıflandırmakta kullanılır.

Bu tezde Baqbah ilçesini kapsayan 2014 yılına ait Landsat Uydu görüntüsünün arazi örtüsünün/kullanımının tematik haritalar elde etmek için sınıflandırılması amaçlanmıştır. Sınıflandırma sürecinde,K-Ortalamlar, Destek Vektör Makinesi ve Yapay Sinir Ağı sınıflandırıcılarından faydalanılmıştır. Söz konusu ileri sınıflandırma tekniklerinin kullanımında kullanıcı tarafından belirlenmesi esas olan parametreler ve bu parametrelerin sınıflandırma sonucuna etkileri araştırılmış ve elde edilen sonuçlar analiz edilmiştir.

Ayrıca sınıflandırma yöntemlerinden (K-Ortamalar, Destek Vektör Makinesi ve Yapay Sinir Ağları) elde edilen sonuçlar karşılaştırılarak olumlu ve olumsuz yönler değerlendirilebilmektedir [3].

1. BÖLÜM


GENEL BİLGİLER VE LİTERATÜR TARAMASI

1.1. Elektromanyetik Enerji ve Işık Kaynağı


Uzaktan algılamanın en önemli enerji kaynağı güneştir. Elektromanyetik radyasyon enerji iletir. Adından da anlaşılacağı üzere, elektromanyetik radyasyon biri elektrik alanı, diğeri manyetik alan olmak üzere iki bileşenden oluşmaktadır. Bu iki alan birbirine ve hareket yönüne dik konumdadır (Şekil 1.1) Elektromanyetik radyasyon yatay bir elektrik alan ve dikey bir manyetik alanla veya tam tersi şekilde iletilebilir. Enerji, iş yapma kapasitesidir. Ve James Prescott tarafından bulunan Joule adında bir birim (J) cinsinden ifade edilir. Radyant enerji, elektromanyetik radyasyonla ilişkili enerji demektir. Bir yerden bir başka yere enerji transferi oranına (örneğin Güneş'ten Dünya'ya) enerjinin akışı adı verilir. Watt cinsinden ifade edilir (W), James Watta göre (1736–1819), mutlak sıfırdaki cisimler haricindeki, bütün cisimler elektromanyetik radyasyon yayar. Aynı zamanda, nesneler diğerk nesnelerin yaymış olduğu radyasyonu da yansıtmaktadır. Yayılan veya yansıyan radyasyonun kaydedilmesi ve davranışının Dünya atmosferi boyunca geçtiğı ve nesnelerle etkileşime girdiğı bilgisinden yararlanarak, uzaktan algılama analizcileri, dünya yüzeyinde bulunan bitki örtüsü, yapılar, toprak, kaya veya su cisimleri gibi özelliklerin yapısı hakkında bilgi edinmektedir. Uzaktan algılama görüntüsünün yorumlanması, elektromanyetik radyasyonun ve bu yüzeyler ile atmosfer arasındaki etkileşimin anlaşılması ile mümkündür. Dalga boyu (λ) bir dalganın ardışık tepeleri arasındaki mesafedir, ve metre cinsinden ölçölür. Simetrik dalgalar, birim zamanda sabit bir noktayı geçen ve Hertz tarafından ölçülen dalga formlarının frekansı (f) cinsinden ifade edilebilir. Elektromanyetik spektrum (EMS), 3×10^8 m/sn hızla hareket eden, dalga uzunluğu nanometreden kilometreye kadar uzanan kesintisiz enerji ortamıdır. Dalga boyu, frekans ve periyod arasındaki ilişkiler şu şekilde belirlenmektedir:

$$f=c/\lambda$$

burada f = frekans, c = ışık hızı (3×10^8), λ = dalga boyunu ifade etmektedir. Tüm elektromanyetik dalgaların seti, uzun radyo dalgalarından mikrodalga ve IR dalga boylarından görünür ışık dalgalarına kadar ultraviyole ve kısa dalga X ve γ ışınlarının ötesine geçen elektromanyetik spektrum olarak adlandırılmaktadır (Şekil 1.1)



Şekil 1.1. Elektromanyetik dalgalar[4].




Şekil 1.2. Elektromanyetik spektrum ve uzaktan algılamada kullanılan bölgeleri[4].

Şekil 1.2.'deki elektromanyetik spektrum, 0,3 μm ile 80 cm arasındaki dalga boylarını gösterir. Dikey kesikli çizgiler ultraviyole (UV) ve yakın kızılötesi (IR'ye yakın) gibi dalga bantlarının sınırlarını göstermektedir. 2 ile 35 cm dalga boyu arasındaki gölgeli

alanlar görüntüleme radarlarının kullanıldığı iki mikrodalga dalga bandını (X bandı ve L bandı) göstermektedir. Eğri, atmosferik transmisyonu gösterir. Yüksek bir transmitans gösteren elektromanyetik spektrumun alanları atmosferik pencereler olarak bilinmektedir. Düşük transmitanslı alanlar opaktır ve dünya'nın yüzeyini uzaktan algılamak için kullanılamaz [4].

1.2. Atmosferik Etkiler

Güneşinin yaydığı elektromanyetik enerji yeryüzüne ulaşmadan önce yoğun bir atmosfer tabakasından geçerek atmosferin bileşenleri ile etkileşime girer. Atmosferin bileşenleriyle etkileşim sebebiyle bu enerji çeşitli değişikliklere uğramıştır. Uzaktan algılama verileri saçılma, emilim ve refraksiyon olmak üzere üç yönlü olarak atmosferden etkilenmektedir. Saçılma atmosferdeki gaz molekülleri, toz parçacıkları ve su damlacıkları ile çarpışmaların etkisiyle ışığın yansması veya kırılması sonucunda meydana gelir [3]. Ortaya çıkan saçılma miktarı, parçacıkların boyutlarına, miktarına, radyasyonun dalga boyuna ve enerjinin geçtiği atmosfer derinliğine bağlıdır. Saçılmanın etkisi, ışınımı yönlendirerek, gelen güneş ışığının bir kısmını uzaya ve dünya'nın yüzeyine yönlendirmektedir. Dalga boyu ne kadar kısa ise, saçılma miktarı da o kadar artmaktadır. Eğer atmosferdeki parçacıklar radyasyonun dalga boyundan çok daha küçük çaplarda bulunursa, rayleigh saçılımı meydana gelir. Genellikle parçacıkların radyasyonun dalga boyuna göre çok küçük çaplara sahip olması durumunda oluşur. Tipik olarak, bu gibi parçacıklar çok küçük toz lekeleri veya nitrojen (N_2) ve oksijen (O_2) gibi atmosferik gazların daha büyük moleküllerinden olabilir. Bu parçacıkların çapları dalga boyundan çok daha küçüktür. Şekil1.3'te gösterilen saçılma yoğunluğundan anlaşıldığı üzere, mavi ışık, kırmızı ışıktan dört kat daha dağınıkken, mor ötesi ışık, kırmızı ışığın neredeyse 16 katı kadar dağılmıştır. Rayleigh saçılması hem gökyüzünün mavi renginin hem de parlak kırmızı ve gün batımında sıkça görülen turuncu renklere yol açan etkendir.




Şekil 1.3. Rayleigh saçılması[1].

Kısa dalga boylarında saçılma çok daha yüksek olur. Refraksiyon, ışığı ileten iki ortam arasındaki temas alanındaki ışık ışınlarının bükülmesidir. Refraksiyon konusuna en bilinen örnekler, kameraların veya büyüteç gözlüğünün merceklidir. Işık, farklı netlik, nem ve sıcaklıktaki atmosferik katmanlardan geçerken de atmosferde kırılma meydana gelir. Bir tabakadan diğerine geçerken ışık ışınlarının bükülmesine neden olan atmosferik tabakaların yoğunluğu bu değişimden etkilenmektedir [1]. Atmosferik absorpsiyon ise, saçılmanın aksine, atmosferik bileşenlere etkili enerji kaybına neden olur. Bu normalde belirli bir dalga boyunda enerjinin emilimine yol açar. Bu açıdan su buharı, karbondioksit ve ozon güneş ışınlarının en verimli emicileridir. Belirli dalgaboyu bantlarında elektromanyetik enerjiyi emme eğiliminde oldukları için, bu gazlar herhangi bir uzaktan algılama sistemi ile spektral olarak "nereden baktığımız" üzerinde yüksek etkiye sahiptirler [3].

1.3. Atmosferik Pencere ve Nesnelerin İmzası

EM spektrumunun bazı enerji dalgaları atmosferden geçemezken, spektrumun belirli bölümlerdeki enerji dalgaları kolayca geçer; buna da atmosferin geçirgenliği denir ve radyasyonun dalga boyu türüne göre değişkenlik gösterir. Atmosferimizi oluşturan gazlar, belirli dalga boylarında enerjiyi emerken, farklı dalga boylarındaki enerji geçmesine müsaade eder. EM spektrumu, bölgelerine absorpsiyon bantları adı verilir. Şekil 2.4'de kahverengi renkle gösterilen emilim bantları belirli bir dalga boyu aralığı ile ilişkili düşük bir iletim değeri ile belirtilir. Absorpsiyon bantlarında uzaktan


algılanmış görüntü elde etmek neredeyse mümkün değildir. Bu yüzden sensörler çoğunlukla spektrumun bu bölümlerine bilgi toplamak için tasarlanmazlar. Absorpsiyon bantlarının aksine, EM spektrumunda, şekil 1.4'te yeşil renkle gösterilen,atmosferin belirli dalga boylarına karşı şeffaf olan (enerjinin az veya hiç emilmemesi) EM spektrumunda alanlar vardır. Enerjinin kolayca atmosferden dünya yüzeyine geçmesine olanak verdiği için,bu dalga boyu bantları atmosferik Bu pencerelerde, dünya ile ilgili



Şekil 1.4. Atmosferik Pencereler[1].

fenomenler hakkında bilgi edinmek için sensörler kullanılır[5]. Dünya yüzeyi çeşitli maddeleri farklı spektral şekillerde yansıtabilir. Buna, spektral bir imza da denebilir. Uzaktan algılama sistemleri yüzeyden yansıyan veya yayılan enerji miktarı birden fazla dalga boyu bandında kaydetmektedir. Fotoğrafik film olarak veya algılayıcı sistemleri tarafından dijital olarak iki yöntemle kaydedilmektedir. Buradan elde edilen verilerden yüzeydeki nesnelerin yorumlanması ve analizi için faydalanılır. Elektromanyetik enerji ile herhangi bir nesne arasındaki etkileşim dalga boyuna bağlıdır. Yansıtılan, absorbe edilen ve geçen enerji miktarı, nesnesinin türüne ve durumuna bağlıdır. Bu faktörler görüntüler üzerinden bir nesneyi sınıflandırmamıza imkan verir. Şekil 1.5 de gösterildiği gibi, uzaktan algılanmış verileri bilgisayarda ortamında doğru ve uygun bir şekilde yorumlamak ve analiz için bitki örtüleri, toprak, su ve benzeri spesifik özelliklerin bilinmesi gerekir. [3]. Bitki örtüsünün yansıtma özellikleri, yaprak kanopisinin yönlendirilmesi ve yapısı da dahil, yaprakların özelliklerine bağlıdır. Belli bir dalga boyu için yansıtılan enerji miktarı, yaprak pigmentasyonuna, yaprak kalınlığına ve bileşimine (hücre yapısına) ve yaprak dokusunda bulunan suyun miktarına bağlıdır. Bu kısımlar fotosentez için bitki tarafından (esas olarak klorofil tarafından) emildiği için, spektrumun görünür bölümündeki mavi ve kırmızı bileşenlerin

yansımaları daha düşüktür; bitki örtüsü yeşil ışığı daha çok yansıtır. Miktarı yaprak gelişimi ve hücre yapısına bağlı olmakla beraber, yansımaları en yüksek NIR(yakın kızılötesi) aralığındadır. Öte yandan, yaprak dokusundaki su SWIR(kısa kızılötesi) aralığındaki yansımaları, üzerinde belirleyici rol oynar; yani su miktarı arttıkça, yansımaları azalmaktadır. Dalga boyu 1.45 ve 1.95 μm civarında olan dalga boyuna su emme bantları adı verilir. Örneğin, yaprakların kuruması, hasat zamanı bitkilerin(örn. Sarıya dönme) renk değiştirmesi, gibi durumlarda spektrumun kırmızı kısmında daha yüksek yansımaları oluşmasını sağlayan fotosentez gerçekleşmemektedir. Ayrıca, yapraklarda kuruma oluşacaktır ve SWIR daha yüksek bir yansımaları sağlayacaktır ancak NIR yansıtması azalabilir. Sonuç olarak, uzaktan algılama sayesinde, bitki türü ve sağlık durumu ile ilgili bilgi toplanabilir. Topraklardan gelen yansımaları, toprak rengi, nem içeriği, karbonat varlığı ve demir oksit içeriği gibi çeşitli faktöre unsurlara bağlı olarak gerçekleşmektedir. Suyun yansımaları oranı bitki örtüsü ve toprağa kıyasla daha düşüktür. Bitki örtüsünün %50'si, toprağın % 30-40'ı bulan yansımaları oranlarına kıyasla, su, enerjinin maksimum %10'luk kısmını yansıtma oranına sahiptir. Elektromanyetik enerji görünür aralıkta ve yakın kızılötesi aralığında su tarafından düşük bir ölçüde yansıtılabilmektedir. Su, çamur ve kir ile dolu iken en yüksek yansımaları oranına ulaşır. Su içeren bitkiler klorofil içeriği sayesinde yeşil ışığı en yüksek düzeyde yansıtılabilmektedir[6].




Şekil 1.5. Toprak, bitki ve su için genelleştirilmiş spektral yansıtım grafiği[3].

1.4. Uzaktan Algılamada Çözünürlük Kavramı

Genel manada, çözünürlük, uzaktan algılama sisteminin mekansal, spektral, radyometrik ve zamansal detayları kaydetme ve görüntüleme kabiliyetini ifade etmektedir. Uzaktan algılamanın pratik ve kavramsal boyutlarını kavrayabilmek için çözünürlük konusunda pratik bilgi sahibi olmak gereklidir. Çözünürlük ölçümü, bir uzaktan algılama sisteminin (belirli mercekler, dedektörler veya sensörler gibi) bireysel araçlarının en uygun tasarım ve ayarlarının belirlenmesinde birincil öneme sahiptir. Görüntü çözünürlüğü bilgisi görüntü üzerinde fazlaca alanda (toprak örüntüsü, jeoloji, su kalitesi, arazi kullanımı veya bitki örtüsü dağılımları... vb.) kaydedilen bilgileri yorumlamak son derece önem arz etmektedir. Estes ve Simonett'a göre (1975), çözünürlük bir görüntüleme sisteminin ince detayları ayırt edici biçimde kaydetme kabiliyetidir [1].


1.4.1. Mekansal Çözünürlük

Uzaysal çözünürlük veya bir pikselin zemin çözünürlük hücresi boyutu uzaktan algılama görüntüsü için en mühim tanımlama unsurudur (Bhuyan ve diğerleri 2007). Bir görüntüde görülebilen ve algılanabilen en küçük muhtemel özelliğin boyutunu belirten detay, sensörün mekansal çözünürlüğüne bağlıdır. Pasif sensörlerin mekansal çözünürlüğü ilk olarak anlık görüş alanlarına (IFOV) bağlıdır. IFOV, belirli bir yükseklikten 'görülen' dünya yüzeyindeki alanı belirleyen görünürlüğünün açısal koniğidir. Başka bir deyişle, Şekil 1.6'da gösterildiği üzere, IFOV, belirli bir anda, tek bir araç tarafından belirli bir yükseklikten görülen alan şeklinde ifade edilebilir (Jensen 2006; Bhatta 2008). Bir IFOV içindeki bilgiden elde edilen görüntü unsuru esasen bir piksel olarak kabul edilir. Homojen bir özellik tespit etmek için, boyutunun genel olarak çözünürlük hücresine eşit veya ondan büyük olması gerekmektedir. Eğer özellik bundan daha küçükse, tespit edilemesi mümkün değildir [7].



Şekil 1.6. Uzaktan algılama uyduları için anlık görüş alanının açısal ve uzunluk olarak ifadesi[3].

X, Y arasındaki uzaklık, uydu görüntüsündeki bir pikseli temsil eden anlık görüntü alanı göstermektedir. Bu uzunluk, sensör tarafından yeryüzünde tespit edilmesi mümkün olan en küçük uzunluktur. Aynı bölge için çoklu çözünürlüğü gösteren Şekil 1.7’de görüldüğü üzere, mekansal çözünürlük artarsa, görüntü daha ayırdedici ve yorumlanabilir hale gelmektedir, veya mekansal çözünürlük azaldığında nesneleri ayırt etmek ve görüntüyü yorumlamak daha da zorlaşmaktadır [3].



Şekil 1.7. Konumsal çözünürlük kavramı. (a) 1 metre, (b) 10 metre, (c) 30 metre çözünürlüklü görüntüler[3].

1.4.2. Spektral Çözünürlük

Spektral çözünürlük, belirli dalga boyunun sayısı ve boyutudur. Uzaktan algılama aletinin bulunduğu elektromanyetik spektrumdaki aralıklar hassastır. Görüntüdeki farklı

özellik sınıfları ve detayları, farklı dalga boyu aralıklarındaki tepkileri kıyaslanarak ayırt etmek mümkündür (Jensen 2006; Bhatta 2008). Farklı nesneler için, geniş bant genişliklerine nispeten daha doğru bir spektral imza sunacak dar bant genişlikleri ile yüksek spektral çözünürlük elde edilir. Spektral çözünürlük yalnızca bant genişliği boyutuna değil, ayrıca bant sayısına bağlıdır. Bantlar ve genişlikleri, multispektral bir görüntü üzerinde bireysel hedeflerin ne kadar ayırt edilebileceğini belirleyecektir. Çoklu spektral görüntülerin kullanılması, tek başına herhangi bir tek bandtan daha yüksek ayırtedici güç sağlayabilir. Her biri 10 nm'lik küçük bant genişliğine sahip çok sayıda bant içeren bir hiperspektral tarayıcı uygun bir çözüm olacaktır[7].


1.4.3. Radyometrik Çözünürlük

Radyometrik çözünürlük, araziden yansıtılan, yayılan veya geri dağılmış radyant akıyı kaydettiği için tarif eder ve yalnızca ayırdedilebilir sinyal seviyelerinin sayısını tanımlar. Bu yüzden, radyometrik çözünürlük, sahne nesnesinin özelliklerini ölçme becerimiz bakımından mühim bir etki yapabilir. 1972'de başlatılan Landsat 1 multispektral tarayıcı, 6 bitlik bir hassasiyetle (0- 63 aralığında değişen bir değerle) yansıyan enerjiyi kaydetti. 1982 ve 1984 yıllarında başlatılan Landsat 4 ve 5 tematik haritalama sensörleri, 8 bitlik (0 - 255 aralığında değişen bir değer) veri kaydetti. Bu nedenle Landsat TM sensörleri orijinal Landsat MSS'e kıyasla radyometrik çözünürlük (hassasiyet) bakımından geliştirmiştir. Coğrafi Göz 1(GEO-EYE 1) ve Dünya Görünümü(WORLD VIEW 2) sensörler 11 bitliktir. Bazı modern sensör sistemleri 12-bit boyutunda radyometrik çözünürlüğe sahiptir. Radyometrik çözünürlük bazen “niceleme seviyesi” adı ile belirtilir. Yüksek radyometrik çözünürlük çoğunlukla olayların daha doğru şekilde uzaktan algılama olasılığını yükseltir.

1.4.4. Zamansal Çözünürlük

Uzaktan algılama sisteminin zamansal çözünürlüğü, sensörün belirli bir alanın görüntüsünü ne sıklıkla ve ne zaman kaydettiği ile ilgilidir. Şekil 1.8 'de gösterilen algılayıcı sistem her 16 günde bir şekilde zamansal çözünürlüğe sahiptir. İdeal olarak, sensör nesnenin benzersiz ayırt edici özelliklerini yakalamak için veri tekrarını alır; örneğin, tarım mahsullerinin her bir coğrafi bölgede benzersiz gelişme fenolojik çevirimi vardır. Belirli tarımsal değişkenleri ölçmek için, fenolojik çevirimdeki kritik tarihlerde uzaktan algılanan verileri elde etmek gereklidir. Çoklu veri imgelerinin

analizi, değişkenlerin zamanla nasıl değiştiğine ilişkin bilgi sağlar. Değişim bilgileri ürünün gelişimini etkileyen süreçler hakkında bilgi sağlar. Bununla birlikte, birçok kentsel uygulamada, özellikle kentsel büyümenin analizi için, yüksek zamansal çözünürlüklere gerek yoktur. Kentsel büyümenin analizi için, 5 yıllık veya 10 yıllık aralıklar yeterli olacaktır. Bununla birlikte, örneklerin bazıları için veri yetersizliği nedeniyle 15 yıllık aralıklar da kabul edilmektedir[8].



Şekil 1.8.Zamansal Çözünürlüğü[8].

1.5. Uzaktan Algılamada Görüntü Analiz Sistemleri

Uydu görüntülerinin analizi ve yorumlanması, farklı hedeflerin belirlenmesi ve ölçülmesiyle imajlardan yararlı ve önemli bilgileri çıkarmak için gereklidir. Hedefler yansıtıp yaydığı radyasyon yardımı ile tanımlanmıştır (nokta, çizgi, alan... vb.). Sensör bir radyasyonu kaydeder ve ölçülür. Yorum elemanları (ton, doku, desen, şekil, boyut, yükseklik ve gölge) olarak adlandırılan görüntüleri yorumlarken bir takım özelliklere ihtiyacımız vardır. Belirli nesnelerin nasıl tanımlanacağı konusunda kılavuzlar sağlar. Elde edilen görüntüler ya analog ya da dijital format olacaktır. Analogdaki görüntü ekranı bir yorumlayıcı tarafından yorumlanmışsa ve sayısal görüntü biçimindeki görüntü ekranı piksellerden oluşacaktır. Görüntünün parlaklık derecesi piksel tarafından belirlenmiştir. Pikseller bilgisayar ortamında bir araya getirilerek sayısal görüntü elde

edilir. Bilgisayardaki özel yazılımlarla piksellerin sayısal değerlerinde değişiklikler yapabilme kabiliyeti, resim yorumlamanın prensiplerini göz önünde bulundurur. Görüntü analiz sisteminde görüntü işlemenin ünlü bir fonksiyonu vardır: ön işleme, görüntü iyileştirme, görüntü sınıflandırma ve analizi [Lillesand ve Kiefer, 1994][3].

1.5.1. Ön İşlem

Uzaktan algılanmış verilerin sayısal analizinde, ön işleme, ana analizin başlangıcı olan işlemleri ifade eder. Ön işleme işlemleri, sisli bir atmosferin etkileri için dijital değerleri ayarlamak için iki aşamalı (1) radyometrik ön işleme tabi tutulmaktadır. (2) geometrik ön işleme (bir görüntüyü kayıt haline getiren) bir harita veya başka bir görüntü ile. ön işleme biçimleri görüntü kalitesini geliştiren ve daha sonra imajdan önemli bir bilgiyi çıkaran bir hazırlık aşamasıdır. Bu araştırmada; uydu görüntülerinde geometrik düzeltme yapılmasına gerek kalmamıştır çünkü atmosferik düzeltme yapılmasına ihtiyaç yoktur. Baqubah şehrine ait olan ve 2014 yılında çekilen görüntü neredeyse bulut içermemektedir [9].

1.5.2. Görüntü İyileştirme

Görüntü İyileştirme, dijital görüntülerin görsel görünümünü geliştirme sürecidir. Dijital analizlerin gittikçe artan önemi nedeniyle, görüntü iyileştirme uzaktan algılamada önem kazanmaktadır. Görüntü iyileştirmesinin asıl amacı belirli bir uygulamayı orijinal görüntüden daha uygun hale getirmek için belirli bir görüntüyü işlemektir. Bir grafik ekranı görüntüleme ve analiz için daha yararlı hale getirmek için kenarlar, sınırlar veya kontrast gibi görüntü özelliklerini vurgular veya keskinleştirir. Görüntü iyileştirmesindeki en büyük zorluk, iyileştirme kriterinin nicelendirilmesidir, bu nedenle çok sayıda görüntü geliştirme tekniği, tatmin edici sonuçlar elde etmek için etkileşimli prosedürler gerektirir. Kontrast, bir görüntü üzerinde bulunan parlaklık değer aralığı anlamına gelir. Kontrast İyileştirme gereklidir, çünkü sensörler çoğu zaman insan görsel sisteminin yetenekleriyle uyuşmayan parlaklık aralıkları üretirler. Bu nedenle insan görüntüsü, fotoğraf filmleri ve bilgisayar ekranları tarafından yerleştirilen dijital görüntülerle iletilen tüm bilgileri görüntü parlaklıklarını yeniden ölçeklendirmek gerekmektedir. Örneğin, mümkün olan maksimum değer aralığı 0-255 (yani 8 bit) ise ancak ekran yalnızca 0'dan 63'e (6 bit) kadar bir aralık gösterebilirse, resim zayıf

sınıflandırmayı hedeflemiştir. k-ortalama ve K-medoids algoritmalarını çalışma süreleri kıyaslayan bu çalışmada K-medoid algoritmasının K-ortalama'ya kıyasla daha yavaş çalıştığı tespit edilmiştir. Aynı zamanda k-medoids algoritmasının kümeleme başarımında K-ortalama algoritmasına göre daha etkili olduğu da ortaya konmuştur. [17].

-Firat ve diğerleri (2012) Türkiye'de Ulusal Meteoroloji Müdürlüğü'ne bağlı çalışan 188 istasyonun yıllık yağış, boylam, enlem ve yükseklik değerleri K-ortalama algoritması ile sınıflandırılmıştır. Kümeleme analizi sonunda küme sayısı 7 olarak belirlenmiştir. Bölgelerin homojenliği bölgesel homojenlik testi ile tespit edilmiştir [18].

-Jian (2012) Renkli uzaktan algılama görüntüleri için çok bölgeli görüntü bölütlenmesi tekniği uygulamıştır. Öncelikle, görüntüleri renklendirmek amacıyla önışlemden geçirilmiştir. Ardından, hedef bölgeler, K-ortalama ve bölge büyütme algoritması ile birleştirilerek bölütlenmiştir. Son olarak, matematiksel morfoloji dikkate alınarak bölütleme sonuçlarının iyileştirilmiştir. Sonuçlar, incelediğinde iyileştirilmesi gereken bazı kusurları olmasına rağmen, önerilen yöntemin etkili bir bölütleme yaptığı gözlenmiştir [19].

-Balaji ve diğerleri (2013) uzaktan algılama görüntü sınıflandırmasında k-ortalama kümeleme yöntemi vasıtasıyla renk özelliğine odaklanmıştır. Belirli bir veri kümesini belirli sayıda küme ile sınıflandırmanın kolay bir yolunu izleyen bu sürecin esas odağı her küme için bir tane küme merkezi tanımlamaktır. Bu süreç sonucunda, küme merkezleri değişiklik devam ettiği sürece yenilenmektedir. Yöntemin uzaktan algılama görüntülerinin bölütlenmesinde başarılı olduğu görülmektedir. Bu algoritmalar, özellikle görüntü tanıma güvenilir ve oldukça etkin sonuçlar sunmaktadır [20].

- Demirkan(2014) kategorik ve kategorik olmayan setlerinin kümelenmesi için k-ortalama algoritmasını iyileştirmeyi hedeflemiştir. Bu amaçla, Jaccard benzerlik ölçeği, veri kümelerinin kategorik kısmı için Öklid uzaklığı yerine K-ortalama algoritması içine yerleştirilmiş ardından iki ölçek bir araya getirilerek kategorik ve kategorik olmayan veriler kümelere ayrılmıştır [21].

-Ngo ve diğerleri (2015) veri kümeleme, doğal kaynak yönetimi, kentsel planlama ve uydu görüntü analizi gibi gerçek dünyadaki çeşitli sorunların çözümünde yaygın olarak

kullanılmaktadır. Bu çalışmada tıbbi, sağlık görüntü analizi, uydu görüntüsü sınıflaması gibi uygulamalar için renk bilgisi ile birlikte mekansal bilgilerden faydalanan bulanık kümeleme geliştirilmiştir. Tip2 Bulanık kümeleme algoritmasında üyelik derecesini hesaplamak için ilgili piksel ve komşuları arasındaki yerel mekansal bilgilerden faydalanan bir yaklaşım tanıtılmaktadır. Öte yandan, mekansal bilgi kullanan yarı kontrollü tip 2 bulanık c ortalama algoritması (SIIT2-FCM), prototip kümeleri, mevcut örnekler üzerinde önceden tanımlanan beklenen merkez noktalarına taşımak için önerilir. Bahsi geçen algoritmalar, arazi örtüsü sınıflamasından ve değişim tespitinden oluşan uydu görüntü analizi problemlerine uygulanmaktadır. Sonuçlar, kullanılan algoritmaların, arazi örtüsü sınıflandırması ve değişim tespiti problemlerinde daha yüksek kalite ve doğrulukta kümeleri oluşturduğunu göstermiştir [22].

-Rozenstein ve diğerleri (2011) Kuzey Negev için daha doğru ve güncel bir arazi kullanım haritası oluşturmak amacıyla mevcut uydu RS verilerini İsrail Coğrafi Bilgi Sisteminden (CBS) gelen verilerle birleştirmek için daha az maliyetli teknikler incelemiştir. Kontrollü ve kontrolsüz eğitim sınıflarının kombinasyonunun, bunların bağımsız olarak kullanılmasından daha doğru bir ürün sağladığı tespit edilmiştir. Öte yandan, yardımcı verileri ve CBS teknikleri bu ürünün doğruluğunu %10 civarında yükseltebilir. Ortaya çıkan ürünün genel doğruluğu % 81'dir. Önerilen tekniğin, değişik zamanlarda elde edilen RS görüntüleri için uygulanmasının, arazi kullanımı değişiklikleri için bir veri tabanı oluşturulmasını kolaylaştırabileceği belirtilmektedir [23].

-Rawat ve diğerleri (2015) Almora bölgesi, Uttarkand, Hindistan'daki Hawalbagh bloğunun arazi kullanımının /mekan-zaman dinamiklerini ortaya koymuştur. 1990 ve 2010 arasındaki 20 yıllık döneme ait, 30 m mekansal çözünürlükte, Hawalbagh bloğunda gerçekleşen değişiklikleri ilişkin Landsat uydu görüntüleri incelemiştir. Kontrollü sınıflandırma metodolojisi, ERDAS 9.3 Yazılımında maksimum olasılık tekniği vasıtasıyla uygulanmıştır. Çalışma alanının görüntüleri, bitki örtüsü, tarım, çorak toprak, yerleşim alanları ve su gövdesi olmak üzere beş farklı grupta toplanmıştır. Elde edilen sonuçlar, son yirmi yılda bitki örtüsü ve yerleşim alanlarının % 3.51 (9.39 km²) ve% 3.55 (9.48 km²) oranında arttığını işaret etmektedir. Öte yandan tarım, çorak toprak ve su kütlesi sırasıyla % 1.52 (4.06 km²), % 5.46 (14.59 km²) ve% 0.08 (0.22

km²) oranında azalmıştır. Araştırma, Hawalbagh blokunun doğası ve yeri için dijital değişim tespit yöntemlerinin önemini gözler önüne sermektedir[24].

-Gandhi ve diğerleri (2015) arazi örtüsü sınıflandırılması için bitki örtüsü İndeksi, arazi örtüsü sınıflaması, bitki örtüsü, su gövdeleri, açık alan, çorak toprak, dağlık alanları, tarım alanı, yoğun orman, zayıf orman alanlarını tespit etmek amacıyla normalize edilmiş fark bitki indeksi (NDVI) kullanılmıştır. Landsat TM uzaktan algılama verileri, çoklu kaynak sınıflandırması gerçekleştirmek için NDVI ve DEM veri katmanları ile birlikte kullanılmıştır. NDVI yöntemi, 0.1, 0.15, 0.2, 0.25, 0.3, 0.35, 0.4 ve 0.5 gibi farklı NDVI eşik değerlerindeki bitki örtüsü gibi karakteristik özelliklerine göre uygulanmıştır. Simülasyon sonuçları NDVI'nin görünür alanın yüzey özelliklerini tespit etmede oldukça yararlı olduğunu göstermektedir; bu da, karar verme işlemi son derece yararlıdır. Bitki örtüsü analizi, insani yardım, hasar değerlendirmesi ve ayrıca yeni koruma stratejileri sağlamak için talihsiz doğal afetlerin öngörülmesinde yardımcı olabilir. Deneysel çalışmalardan elde edilen sonuçlara göre orman veya çalılık arazisi ve çorak toprağı örtüsü türleri sırasıyla 2001 ve 2006 yılları arasında sırasıyla% 6 ve% 23 oranında azalmıştır, tarım arazileri, yerleşim alanları ve su alanları sırasıyla yaklaşık% 19,% 4 ve% 7 oranında artmıştır. Eğrilik, Plan eğriliği, Profil eğriliği ve Islaklık indeksi alanları da tahmin edilmektedir [25].

-Bakr ve diğerleri (2010) Mısır'ın Batı Deltası çöl bölgesi(Bustan) 1984, 1990, 1999, 2004 ve 2008 çekilen çok zamanlı 30m çözünürlüklü Landsat görüntüleri üzerinden bu alandaki arazi örtüsünde meydana gelen zamansal değişiklikler. belirtilen aralıklarda hem Hibrid bir sınıflandırma yaklaşımı hem de NDVI yardımıyla tespit edilmiştir. Hibrid sınıflandırma sonuçları, bu alanın kentsel veya inşa edilmiş arazi, tarım arazisi, su ve kısır arazi olmak üzere dört arazi örtüsünden oluştuğunu göstermiştir.İslah işlemleri 1984'ten 1990'a kadar kısır toprak yapısında olan çalışma kayda değer değişiklikler yapmıştır. Üretilen tematik görüntüler üzerinde yapılan incelemenin % 94.5 -% 100 arası tutarlılığa ulaşıldığını göstermektedir[26].

-Han ve diğerleri (2013) Bu çalışmada, doğal sahnelerin çok bölgeli renkli ölçekli görüntülerinin bölütlenmesi sorununa bir çözüm olarak bulanık mantık tabanlı yeni bir varyasyonel bölütleme tekniğini önermektedir. Söz konusu bölütleme tekniği: (1) PCA tabanlı bir indirgeme yöntemi kullanarak geleneksel varyasyonel tabanlı bölütleme modellerinden daha etkili bölütleyebilme, (2) Bulanık üyelik fonksiyonlarının

geometrik yapısını korumak amacıyla, dışbükey olmayan bir düzenleyici terim önermekte, (3) Lagrange çarpanı yöntemi ve iteratif ağırlıklandırma içeren hızlı bir iterasyon algoritması vasıtasıyla daha verimli bölütleme gibi avantajlara sahiptir. Kapsamlı görsel değerlendirme deneyleri önerilen modelin, etkili bir bölütleme performansı ortaya koyduğunu ve çeşitli kantitatif indeksler açısından da son derece verimli olduğunu göstermektedir [27].

-**Ng (2017)** PCA tekniği ile boyut indirgenmiş görüntü ve gerçek görüntü kalitesi kıyaslanmıştır. PCA tarafından boyut azaltma işlemi çoğunlukla (1) görüntü verilerinin normalleştirilmesi (2) görüntü verisinden kovaryans matrisini hesaplanması (3) Tekil Değer Ayrışımının gerçekleştirilmesi (4) Azalan özelliklere sahip yeni temel için görüntü verisinin izdüşümünün belirlenmesi şeklinde dört temel adım içermektedir. Deneysel sonuçlara göre, PCA tekniği gerçek görüntünün temel özelliklerini korurken boyutunda % 35.3 oranında azalma sağlamıştır. Bahsi geçen yöntem görüntünün internet aracılığıyla gönderilmesi, bilhassa mobil cihazlar tarafından indirilme işlemi açısından farkedilir bir gelişme ortaya koymuştur[28].

1.7. Yapay Sinir Ağları

- **Erbek ve diğerleri (2010)** Landsat TM verilerinden faydalananarak arazi kullanım sınıflandırması için çok katmanlı algılayıcı (MLP) ve öğrenmeli vektör kuantalama (LVQ) şeklinde iki denetimli yapay sinir ağı sınıflandırıcısının performansını daha geleneksel maksimum olasılık yaklaşımı ile kıyaslamıştır. Çok katmanlı veri sınıflandırma yönteminin, geleneksel maksimum olasılık sınıflandırması yönteminden daha verimli olduğu gözlemlenmiştir. İşlem süresine açısından, YSA yaklaşımları maksimum olasılık sınıflandırıcısına göre çok daha zaman almıştır. Sonuç olarak, MLP ANN tekniği en verimli sonuçları vermiştir. LVQ da ANN sınıflandırıcısının kullanımı kolay ve etkili bir yöntem olmasına rağmen, performansı en düşük olan yöntemdi. Dijital değişim algılama analizi için sinir ağı modelleri etkili bir değişim tespit tekniği olarak büyük bir potansiyel göstermiştir [29].

-**Srivastava ve diğerleri (2012)** Landsat görüntülerinin sınıflandırılması için en verimli yöntemi belirlemek amacıyla maksimum olasılık sınıflandırma (MLC), destek vektör makineleri ve yapay sinir ağları (YSA) karşılaştırmışlardır. Genel analiz sonuçlarına göre, YSA kernal tabanlı DVM (doğrusal, radyal tabanlı, sigmoid ve polinom) ve MLC'den üstün performans göstermiştir. Ardından, en iyi araç (YSA), Iowa'daki

Walnut Creek alanının bir bölümünde değişim tespiti amacıyla uygulanır. Elde edilen sonuçlara göre kentsel alanlarda artış gözlenmiş ve tarımsal uygulamalar büyük ölçüde değişmiştir [30].

-Sammouda ve diğerleri (2014) günümüzde uydu görüntüleri tarımsal yönetim ve izleme için etkin bir yöntem olarak kullanılmaktadır. Öte yandan, çevre koşulları, zayıf çözünürlük ve zayıf aydınlatma gibi etkenler sebebiyle en zorlu görüntü parçalama sorunlarından biridir.. Piksel kümeleme, farklı arazi örtü tiplerine ait homojen görüntü bölgelerini spektral özelliklerine göre dayanarak tespit etmenin yaygın bir yöntemidir.

Hopfield Sinir Ağı (HNN), tarım uydu görüntüleri için Pixel kümeleme tabanlı segmentasyon yöntemi olarak belirtilmiştir. Analiz sonuçları, arıcıların gerçek arı yem bölgeleri hakkında yönlendirme konusundayardımcı olacaktır [31].

-Colkesen ve diğerleri (2015)Bu çalışmada Gebze Teknik Üniversitesi (GTÜ) tarafından çekilen 2m mekansal çözünürlüklü, Word View 2 uydu görüntüsünün veri kümeleri setlerini Geleneksel En Yakın Komşu (NN) ve destek vektör makineleri (DVM) vasıtasıyla sınıflandırılmıştır.Elde edilen Sonuçlarına göre, DVM algoritması mevcut 40 bant içeren veri kümesi ile% 88.23 ile maksimum sınıflandırma doğruluğu sağlamıştır.Öte yandan, 20 seçilmiş bant içeren YSA algoritması %83.74'lik oranla en iyi sınıflandırma performansını ortaya koymuştur. Genel manada, DVM-RFE algoritması vasıtasıyla sınıflandırma doğruluğundaki gelişmenin etkisiyle gerçekleşen,% 60-80'lik azalma soununda veri kümesi bouyutu% 5 olmuştur [32].

- Basaeed ve diğerleri (2016)uzaktan algılama görüntüleri için bant içi ve bant içi füzyon ile birleştirilmiş, Evrişimsel Sinir ağları (ESA)'in güçlendirilmiş bir versiyonune dayalı bir bölüteme yöntemi sunmuşlardır.Yüksek hassasiyet sağlayabilen, özellikle geliştirilmiş mekansal, spektral ve zamansal çözünürlü görsel veriler için genel bir bölüteme yöntemi geliştirmek son derce zordur. Bahsi geçen yöntem, çeşitli çoklu spektral bantlar vasıtasıyla bölge sınırlarının konumune ilişkin müstakil olasılık haritaları geliştiren ve bunları ortalama bantlar arası füzyon şeması yardımıyle birleştiren bir füzyon çerçevesidir. Nital ve nicel sonuçlara göre, önerilen bölüteme tekniği mevcut teknolojik yöntemlere göre daha başarılı olmuştur [33].

-Shao ve diğerleri (2017).Albemarle-Pamlico Estuary System (APES) 'yi çalışma alanı olarak belirleyip Çalışmalarında arazi örtüsünün sınıflandırılması için DVM uygulamışlardır. DVM için doğruluk% 77 ile % 80 aralığında iken, sırasıyla. çok katmanlı perseptron ve regresyon ağaçları için% 67 ila%76 ve% 62 ila% 73'e aralığındadır. Bu sonuçlara göre, DVM özellikle küçük eğitim alanları için etkin şekilde sınıflandırma yapabilmektedir. Üç aşamalı bir sınıflandırma için, en iyi genel doğruluklar 2001 ve 2009 yıllarında sırasıyla% 80 ve% 83 olarak gözlemlenmiştir [34].

-Sharma ve diğerleri (2017) orta çözünürlüklü uzaktan algılama görüntülerinin sınıflandırılması için yeni bir ESA sistemi önermiştir. Özellikle Landsat verileri için, çok boyutlu TOA yansıma verilerinden yama tabanlı örnekler hesaplamıştır. Önerilen sistem piksel tabanlı geleneksel sinir ağı, piksel tabanlı ESA ve yama tabanlı sinir ağı ile kıyaslanmış ve ,sınıflandırma sonuçları, önerilen sistemin sadece genel değil kategorik sınıflandırma doğruluğunu da dikkat çekici ölçüde iyileştirdiğini göstermiştir. Bu sistem derin ESAden büyük çözünürlüklü uzaktan algılama verilerini birleştirerek, geniş alanlarda, oldukça doğru arazi örtüsü veri setleri üretilebilmektedir [35]

-Singh ve diğerleri (2017) Genetik Algoritma (GA) ve Radyal Tabanlı Fonksiyon Ağları (RBFA) temelli uydu görüntülerinin sınıflandırılmasında yarı kontrole dayalı bir teknik geliştirmişlerdir. Uydu görüntüsü sınıflandırmada çözümü şart olan iki mühim sorun bulunmaktadır. İlk husus karışık piksel problemi ve diğeri de geniş ölçüde veri işlemedir. RBFA işlevi, geniş bir parametre kümesi içeren, sonuçları genelleştirebilen ve gürültüye karşı bağımsızlık kazanabilen güçlü bir ağıdır. Bir RBFA öğrenebilir ve daha öncede bilmediği verilere tepkiler verebilir. Öğrenme algoritması ve çekirdek nokta seçimi RBFA'nin verimini, önemli dercede etkilemektedir. Bu yüzden, çekirdek seçimi için GA'dan faydalanılmaktadır.Bahsi geçen yöntem, Dongting Gölü'nde bulunan taşkın alanların tespitinde Landsat 8 OLI görüntülerini sınıflandırmak için Güney Çin'de kullanılmıştır. Performans analiz sonuçlarına göre mevcut üç yöntem kıyaslandığında ve hata matrisi hesaplandığında,önerilen sınıflandırıcının oldukça etkili ve verimli olduğu gözlemlenmiştir [36].

1.8. Destek Vektör Makineleri

-**Szuster ve diğerleri** (2011) düşük-orta ölçekli gelişmenin gözlenebildiği bir tropikal kıyı bölgesinde destek vektör makinelerinin görüntü sınıflandırma tekniğinin performansını incelenmiştir. Bu yaklaşımın genel ve bireysel sınıflandırma sonuçları, maksimum olasılık sınıflandırıcısı ve yapay sinir ağı teknikleri ile kıyaslanmıştır. İnceleme için Tayland'daki Koh Tao'nun 15 metrelik mekansal çözünürlüklü ASTER görüntüsünden faydalanılmıştır. Destek vektör makineleri, bina gibi insani yapıların, hemen hemen aynı spektral imzaya sahip kıyı kayası ve kumlu plaj gibi diğer arazi örtü türlerinden ayırt etmenin zorlayıcılığına güçlü bir direnç göstermiştir. Bahsi geçen arazi örtüsü türlerinin karışımı ile kıyı manzaralarını sınıflandırmak için, orta çözünürlüklü ASTER görüntüsü, son derece uygundur.

Katmanlı sınıflandırmada destek vektör makinesinin sahip olduğu potansiyeli ortaya koymak ve öteki tropik ortamlarda olası uygulamalarını belirlemek için daha ileri incelemeler gerekmektedir [37].

-**Üstüner ve diğerleri** (2013) İzmir Menemen için 8 Ekim'de çekilen $7.5 * 6.7 \text{ km}^2$ ölçülerinde olan 5 m mekansal çözünürlüklü RapidEye multispektral uydu görüntüsü ve 400-850 nm aralığında beş optik bantta çoklu-spektral görüntüyü incelemişlerdir. İncelemede Destek Vektör Makineleri (DVM) yöntemi olan makine öğrenme algoritmalarından biri uygulanmıştır. Yedi arazi kullanım kategorisi içeren bu alan çalışması, Rapid Eye uydu görüntüsünün kırmızı kenar kanalının sınıflandırma doğruluğunu etkilediğini ortaya koymuştur. Bu çalışma sonuçlarına göre, Rededge bandı sınıflandırma doğruluğunu artırmaktadır ve bütün DVM modelleri içerisinde radyal temel işlevi çekirdeği, arazi kullanımı sınıflandırması için en yüksek genel ve kappa doğruluğu (% 91.3 ve 0.8974) sağlamaktadır.

-**Melgani ve diğerleri** (2004) hiperspektral uzaktan algılama görüntü sınıflandırma Sorununu destek vektör makineleri (DVM'ler) çözmeyi amaçlamıştır. Ardından, DVM'ler ile parametrik olmayan fonksiyonel sinir ağları ve K-en yakın komşu sınıflandırıcısının performansları arasında kıyaslama yapmışlardır. Çalışma sonuçları, DVM'lerin geleneksel parametrik olmayan sınıflandırıcılardan (RBF sinir ağları ve K-nn sınıflandırıcısı) sınıflandırma doğruluğu, hesaplama süresi ve parametre ayarına kararlılık bakımından daha yüksek etkiye sahip olduğunu ortaya koymuştur. Bununla

birlikte DVM'ler, bir özellik çıkarma / seçim prosedürünün ve konvansiyonel sınıflandırıcı birleşimine dayalı geleneksel model tanıma yaklaşımından daha etkili olduğu düşünülmektedir[38].

-Kavzoglu ve diğerleri (2009) Landsat ETM + ve Terra ASTER görüntüleri vasıtasıyla Türkiye'nin Gebze bölgesinin arazi örtüsü sınıflandırmasında DVM'lerden faydalanmışlardır. Veri setlerinin sınıflandırılmasında, polinom ve radyal temel çekirdek fonksiyonları ve tahmin edilen optimum parametreler kullanılmış ve sonuçlar detaylı bir şekilde incelenmiştir. Bu çalışma DVM'lerin özellikle radial tabanlı fonksiyon çekirdeği kullanıldığında genel ve bireysel sınıf doğrulukları açısından maksimum en yüksek olasılık sınıflandırıcısına kıyasla yüksek etkisini ve sağlamlığını ortaya koymuştur[39].

-Kavzoğlu ve diğerleri (2010) DVM'lerin performansını çekirdek fonksiyonu ve belirlenen parametre değerleri bakımından detaylı olarak incelemişlerdir. Çalışmada en yaygın dört çekirdek fonksiyonunun sınıflandırma doğruluğu üzerindeki etkileri incelenmiştir. Sonuçlar kullanılan alınan veri seti için radyal taban fonksiyonu ve Pearson VII fonksiyon çekirdeklerinin maksimum performansı (>% 94) ortaya koyduğunu göstermiştir. Öte yandan, normalleştirilmiş polinom çekirdeği, bütün DVM modelleri içerisinde en düşük sınıflandırma doğruluğu (% 91,78) sağladığını ve bütün DVM'lerin en yüksek olasılık sınıflandırmasından daha tutarlı sonuçlar sağladığı tespit edilmişti [40].

-Maulik ve diğerleri (2011) kendi kendine yetiştirme yaklaşımını esas alan yarı denetimli bir destek vektör makinesi ortaya konmaktadır ve ardından uzaktan algılama görüntülerinin piksel sınıflandırma problemini çözmeyi amaçlayan yarı kontrollü DVM sınıflandırıcıları topluluğunu kurmuşlardır. Yarı kontrollü destek vektör makineleri (DVM'ler), marj maksimumlaştırma prensibinin etiketli ve etiketlenmemiş örnekler üzerinde tatbik edilmesini temel almaktadır. Önerilen tekniğin etkinliği için ilk olarak iki sayısal uzaktan algılama verileri kapsamında ve ardından uzaktan algılamada çeşitli arazi örtüsü bölgelerinin tespit görüntüleri incelenmiştir. Bu çalışmada, bu öğrenme şemasının doğruluk seviyesini yükseltebileceği gözlemlenmiştir[41].

-Mountrakis ve diğerleri (2011) Uzaktan algılamada destek vektör makineleri (DVM'ler) uygulamalarını gösterdi. Uzaktan algılama uygulamaları için ortak bir

sınırlama olan sınırlı eğitim örnekleri bile olsa genelleme yeteneği nedeniyle DVM'ler özellikle caziptir. Bununla birlikte, aynı zamanda, elde edilen sonuçları önemli ölçüde etkileyebilecek belirleme problemi vardır. DVM'nin en önemli özelliği, sınırlı miktarda ve / veya eğitim verisi kalitesinden iyi bir şekilde genelleme kabiliyetidir. Geri yayımlı Sinir ağları gibi alternatif yöntemlerle karşılaştırıldığında, DVM'ler çok daha küçük bir eğitim numunesi boyutu kullanarak benzer doğruluk üretebilir. DVM'nin ek bir avantajı, rasgele başlangıç değerleri ve mimarileri kullanarak sınıflandırıcı eğitiminin tekrar edilmesine gerek olmadığıdır. Bu özellikle yararlıdır, çünkü uzaktan algılanan görüntülerden elde edilen veriler genellikle bilinmeyen dağılımlara sahiptir. Bu, DVM'lerin maksimum olasılık sınıflandırmasına dayalı tekniklerden daha iyi performans elde etmelerini sağlar[42].

-Maulik ve diğerleri (2013) Uzaktan algılanan veriler üzerinden gerçekleştirilen arazi örtüsü sınıflandırması, ve farklı kategorilerin karmaşık arazi örtüsünün doğru haritalanması için etkili sınıflandırma metodlarına ihtiyaç duyulduğunu belirtmektedirler. Öte yandan, eğitim örneği, uygun kontrollü sınıflandırıcıları geliştirmenin önünde bir sorun teşkil etmektedir. Bunun birlikte uzaktan algılama görüntülerinde marjlara ilişkin ilave bilgi kaynağı olarak faydalanılabilecek yeterli miktarda etiketlenmemiş veri bulunmaktadır. Değerli etiketlenmemiş verilerin tamamını kullanabilmek için, filtrelemenin bir transdüktif DVM'ye entegrasyonu tavsiye edilmektedir. Küçük boyutlu iki etiketli resim veri kümesi kullanımı ile bahsi geçen metodun ve iki büyük etiketlenmemiş görüntü veri kümesi, üzerindeki etkisi incelenmiştir. Sonuçlar incelendiğinde, bahsi geçen sırasıyla Progressive Transductive (PTSVM) ve Low Density Separation (LDS) endüktif DVM (IDVM) sınıflandırıcıları, etiketli veri kümeleri durumunda büyük alanlar üzerinde % 4.5-7.8, % 0.8-2.6 ve % 0.9-2.2 oranında ortalama genel doğruluk ürettiği endüktif SVM (ISVM) ortaya konmuştur. Sonuç olarak, önerilen yöntemin etiketlenmemiş örneklerin verilerini etkili bir şekilde filtreleyebildiği tespit edilmiştir [43].

-Liu ve diğerleri (2013) uzaktan algılama arazi örtüsü sınıflandırması isorununa bir çözüm olarak kendi kendini eğitme temelli güncel bir yarı kontrollü DVM modelini uygulamışlardır. Bu yaklaşımın en temel özellikleri şunlardır: (1) Parçacık Sürü optimizasyon algoritmasına dayanması ve (2) etiketlenmiş noktaların belirlenmesinde bulanık Gustafson–Kessel kümeleme algoritmasını uygulamasıdır. Önerilen yöntemin

verimliliği ilk olarak uzaktan algılama verilerinden çıkarılan numuneler üzerinden incelenmiştir ve ardından uzaktan algılama görüntülerindeki farklı arazi örtü bölgeleri tespit edilmiştir. Çalışma, bu öğrenme şemasını algoritması kullanımının doğruluğun düzeyini yükselttiğini ortaya koymuştur [44].

-Jain ve diğerleri (2017)Self Organizing Maps (SOM) vasıtasıyla Destek Vektör Makinesi'ni (DVM) optimize etme prensibine dayanan metodoloji ile piksel yoğunluklarının bireysel olarak Posterior Probability kıyaslaması yoluyla iç ve dış Piksel sınıflandırılması gerçekleştirilmiştir. Bu çalışmada iki kademeli bir yöntem uygulanmaktadır. İlk olarak Destek Vektör Makinelerini vasıtasıyla görüntüdeki önemli özellikleri eğitilmektedir. İkinci aşama ise, iç ve dış piksellerin tespit edilmesi ve En Uygun eşik değer ve olasılığın hesaplanmasıdır. 16 ve 9 sınıf içeren iki veri kümesi üzerinde uygulanan yöntemlerin, Doğruluk ve Kappa ve Confusion Matrix bakımından mevcut sınıflandırma yöntemlerinden daha etkili performansa sahip olduğunu ortaya koymaktadır [45].

- Petropoulos ve diğerleri (2012) Klasik bir Akdeniz ortamında arazi kullanımını / örtüsünü tespitinde iki sınıflandırma algoritması (piksel tabanlı destek vektör makineleri (SVM'ler) ve nesne tabanlı sınıflandırma algoritması) ve Hyperion sensörünün performanslarını incelemiştir. Hyperion hiperspektral sensörü, 242 spektrum bandında 30m'lik en yüksek spektral çözünürlükte nesneler hakkında veri sağlamaktadır. Bu çalışma sınıflandırıcıların, arazi kullanımı / arazi örtü haritalanmada oldukça etkili olduğunu ve nesne tabanlı yaklaşımın, SVM sınıflandırmasından daha iyi sınıflandırma doğruluğu, Kappa istatistikleri ve üstün performans sergilediğini kanıtlamaktadır. Kullanılan sınıflandırma algoritmalarının güçlü ve zayıf yönleri olmasına rağmen, McNemar'ın ki-kare analiz sonuçları, nesne yönelimli yaklaşımın DVM'den daha üstün olduğunu ve hiperspektral uzaktan algılama verisinin etkinliğini istatistiksel olarak da ortaya koymaktadır [46].

1.9. Segmantasyon ve Nesne Tabanlı Sınıflandırma.

-Grinias ve diğerleri (2016) uydu görüntüleri vasıtasıyla kentsel alanlarda kontrolsüz anlamsal ayrıştırma yapı tanımına ilişkin güncel bir metot ileri sürmüşlerdir. Kontrolsüz bölütleme otomatik "bina" ve "yol" algılama bölgelerini, kontrolsüz bölgeleri temel almaktadır. Markov Random alan modelini esas alan yeni bir bölütleme algoritması

sunmuşlardır. Rasgele orman tekniği ile anlamlı bir sınıflandırma oranına erişim olanağı incelenmiştir. Bunun sonucunda da, kısıtlı özellik ile üstün bir sınıflandırma performansı sağlanabileceği tespit edilmiştir.

-Wang ve diğerleri (2014) yüksek çözünürlüklü uzaktan algılama görüntü bölütleme için ve Segmentasyon doğruluğunu yükseltmek amacıyla konvansiyonel bölütleme algoritması olan JSEG (J-Segmentasyon) 'da bulunan kısıtlılıkları çözmek amacıyla güncel yeni bir çok ölçekli bölütleme algoritması olan Wavelet-JSEG (WJSEG) uygulama fikrini ileri sürmüştür. WJSEG, Dalgacık dönüşümüne dayalı çok ölçekli bir analiz aracı, bölge birleştirme, renk kuantumlanması, çoklu ölçek bölütleme gibi üç özelliğiyle öne çıkan ileri bir JSEG formudur. Deneyler, yüksek çözünürlüklü SPOT 5 pan keskinleştirilmiş multispektral görüntü ve IKONOS pankromatik görüntü üzerinde gerçekleştirilmiştir. Konvansiyonel JSEG algoritması ve eCognition adlı eski ticari yazılım aracılığıyla edinilen görüntülerin kıyaslandığı analiz sunulan WJSEG algoritmasının verimliliğini ve güvenilirliğini ispatlamıştır [47].

-**Su ve diğerleri** (2017) Nesneye dayalı görüntü analizinde, doğru bölütlemenin nasıl sağlanacağı, genellikle görüntü sınıflandırması veya hedef tanıma sürecinden önce aşılması gereken mühim bir sorun olduğunu ifade etmektedirler. Bölütleme değerlendirme tekniği için yürütülen çalışma, bu sorunun çözümünde kilit öneme sahiptir. Güncel değerlendirme yöntemlerinin hemen hemen hepsi sadece küresel performans değerlendirmesine eğilimindedir. Öte yandan, bu metotlar, genel performansı çok benzer iki bölütleme sonucunun çok çeşitli yerel hata dağılımlarına ilişkin durumlar üzerinde etkili değildir. Bu problem çözmek amacıyla, bu çalışma, yerel ve küresel olarak bölütleme hatalarını ölçebilecek bir yaklaşım benimsemektedir. Her bir referans için coğrafi nesnenin aşırı ve alt bölütleme hatasını tespitinde, örtüşen bölge matrislerinden faydalanılır. Herkesin referans yer nesnelerinin hata değerleri, alan ağırlıklı toplam yardımıyla toplanır, bunun sonucunda da küresel değerler elde edilebilir. Bu çalışma, çeşitli yüksek çözünürlüklü görüntülerin üzerinde yaklaşımın küresel değerlendirmeyi kısmen diğer iki küresel değerlendirme metodu ile eşit etki yaptığını ortaya koymaktadır [48].

1.10. Optimizasyon Tabanlı Sınıflandırma.

-**Wang ve diğerleri** (2012) Karınca koloni (ACA) sezgisel optimizasyon algoritmasının diğer bölütleme yöntemleriyle kolayca bütünleştiğini belirtmiştir. Karınca koloni ve Bulanık c ortalama (FCM) gürültüyü azaltarak görüntü bölütleme hızını oldukça yükseltebilmektedir. ACA FCM temelli görüntü bölütleme yöntemi geleneksel tekniklerle karşılaştırılmıştır. Sonuç olarak, ACA FCM'nin hedefi çabuk ve doğru şekilde kümelere ayırabildiğini ve görüntü bölütleme için verimli bir teknik olduğu belirlenmiştir [49].

-**Kapoor ve diğerleri** (2017) 14 Mart 1991'de ve 2 Mart 2016'da Yeni Delhi için çekilen uydu görüntülerini kullanmışlardır. Görüntülerin her biri 3, 4 ve 5 kümeye bölünmüştür. Genel olarak, üç küme için en verimli sonuçlar elde edilmiştir. GWO (Grey Wolf Optimizer) algoritmasına dayanan 3 küme ile en iyi bölümlenmiş sonuçlar elde edilmiştir.

(GWO)'nun, hesaplama açısından verimliliği ve doğruluğunun Davies-Bouldin (DB) indeksi, ortalama küme arası mesafe ve ortalama küme içi mesafe bakımından birçok durumda oldukça yüksektir [50].

-**Wang ve diğerleri** (2017) Optimal DVM vasıtasıyla görüntü sınıflandırmasını ileri sürmüştür. Ayrıca, DVM parametreleri ve özellik seçimi, genetik algoritma ile birleştirilmiş değiştirilmiş bir karınca koloni algoritması ile integralsal olarak incelenmiştir. Sonuçlar ikili parçacık sürü optimizasyon (BPSO) algoritması, ikili karınca koloni optimizasyon (BACO) algoritması, ikili diferansiyel gelişim (BDE) algoritması, genetik algoritma (GA) ve ikili guguk kuşu (BCS) algoritması gibi sezgisel algoritmalar ile kıyaslandığında, önerilen tekniğin etkili, adaptif diğer yöntemlerden daha üstün performans sahip olduğunu ortaya koymuştur [51].

2. BÖLÜM

GÖRÜNTÜ SINIFLANDIRMA


2.1. Görüntü Sınıflandırması

Görüntü sınıflandırması, belirli bir etiket kümesini veya arazi örtüsü temalarını elde etmek için bir görüntünün tüm piksellerini veya uzaktaki uydu verilerinin kategorize edilmesi süreci olarak tanımlanır (Lillesand, Keifer 1994) Şekil 2.1'da gösterildiği gibi. Genel görüntü sınıflandırma prosedürleri şunları içerir:

- 1- Görüntü sınıflandırma şeması: bunlar genellikle şehir, tarım, orman alanları gibi bilgi sınıflarıdır. Alan araştırmaları yürütmek ve çalışma alanının yer bilgisini ve diğer yardımcı verileri toplamaktadır.
- 2- Radyometrik, atmosferik, geometrik ve topografik düzeltmeler, görüntü iyileştirme ve başlangıç görüntü kümelemesi de dahil olmak üzere görüntünün ön işleme tabi tutulması.
- 3- Resmin temsili alanlarını seçin ve ilk kümeleme sonuçlarını analiz edin veya eğitim imzaları oluşturulur.
- 4- Görüntü sınıflandırma algoritmaları işletmektedir.
- 5- Son işlem: tam geometrik düzeltme ve filtreleme ve sınıflandırma dekorasyonu.
- 6- Doğruluk değerlendirmesi: sınıflandırma sonuçlarını arazi çalışmaları ile karşılaştırılır.



Test alanının SPOT multispektral görüntüsü,



SPOT görüntüsünden türetilen tematik harita

Şekil 2.1. Görüntü sınıflandırmasını gösterir[10].


2.1.1. Kontrolsüz sınıflandırma

Kontrolsüz görüntü sınıflandırma, resim yorumlama algoritmasının, yansıma değerlerine dayalı olarak bir çok bilinmeyen piksel sayısını, analistin yönü olmayan sınıflara veya kümelere ayırdığı bir yöntemdir. Kontrolsüz sınıflandırma için kullanılan en sık kullanılan iki kümeleme yöntemi vardır: K-ortalama ve İteratif Kendiliğinden Organize Veri Analizi Tekniği (ISODATA). Bu iki yöntem tamamen piksel tabanlı istatistiklere dayanır ve üzerinde çalışılan temaların özellikleri hakkında önceden bilgi içermez[10].

2.1.1.1. K-Ortalama yöntemi.

Şekil 2.2’de açıklanan bu teknik iki boyutlu bir özellik uzayında birbirinden iyi ayrılmış iki nokta grubunu göstermektedir. Her grubun üyeleri ayrı iki değişkenli normal dağılımlardan alınmıştır. İki grup nokta grubunun olduğunu bilinmediği varsayılmaktadır; ancak özellik alanındaki grup merkezlerinin konumlarını

bilinmemektedir. Noktalar '1₀' ve '2₀' bu pozisyonlarda ilk tahminleri temsil eder. Daha önce açıklandığı gibi, 'merkeze en kısa mesafe' karar kuralı, bilinmeyen her noktayı etiketlemek için kullanılır (şekilde bir nokta ile gösterilir). '1₀' ve '2₀' olarak etiketlenen ilk küme merkezlerinden noktanın göreceli Öklid uzaklığına bağlı olarak '1' veya '2'dir. Böylece, küme merkezleri 1 ve 2'ye (kare) Euclidean mesafeleri her nokta (q; Burada q örnek bir noktadır.) için (d^2q_1 ve d^2q_2) hesaplanır, ve d^2q_1 d^2q_2 'den küçükse q'ya '1' etiketi veya d^2q_2 d^2q_1 'den küçükse '2' etiketi tahsis edilir. Öklid uzaklığı eşitse, nokta istenen kümeye atanır (Örneğin '1' etiketi tahsis edilebilir.) (Burda d:Distance, mesafedir.). (d ve q ilgili resimde bulunmamaktadırlar). Bu etiketleme dizisinin sonunda, '1' etiketli tüm noktadaki değerlerin ortalaması, özellik alanının eksenlerinin her biri için hesaplanır, ve aynı, '2' etiketli tüm noktalar için, iki grup noktasının merkezinin özellik alanındaki koordinatları vermek için yapılır. Bu yeni merkezler diyagramda '1₁' ve '2₁' olarak gösterilir. noktalar, tekrar centroidlerin yeni konumlarına göre en kısa mesafeden-ortalama karar verme kuralı kullanılarak tekrar etiketlenir. Yine, bu ikinci iterasyonda '1' etiketli noktaların merkezinin konumu hesaplanır ve '1₂' olarak gösterilir. '2' etiketli noktaların merkezinin yüzdesi benzer bir şekilde bulunur ve '2₂' olarak gösterilir. Bütün noktalar ile bu yeni merkezlere olan uzaklıklar hesaplanır ve bir çift yeni merkez noktası bulunur ('1₃' ve '2₃'). Bu merkezler şimdi bu örnek için yapay olarak üretilen iki grup noktasının merkezindedir; ve noktaların yeniden etiketlenmesi, centroidlerin konumunda herhangi bir değişime neden olmaz, dolayısıyla bu pozisyon son olarak alınır.



Şekil 2.2. k-ortalama [4].

2.2. Kontrollü sınıflandırma

Görüntü sınıflandırmasında ana adımlardan birisi, özellik alanının 'bölümlendirilmesi' dir. Kontrollü sınıflamada, bu, örnek alanların (eğitim alanları) tanımlanmasıyla sınıfların spektral özelliklerini tanımlayan bir operatör tarafından gerçekleştirilir. Kontrollü sınıflandırmada, ilgi alanı, operatör tarafından bilinmelidir. Kontrollü yöntemler, seçilen algoritma uygulanmadan önce kullanıcının girdi gerektirir. Bu veri giriş, alan çalışması, hava fotoğrafı analizi, raporlar veya ilgi alanının uygun haritalarının incelenmesinden elde edilebilir. Kontrollü yöntemler ya istatistiksel ya da istatistiksel olmayan algoritmalar kullanılarak uygulanır. İstatistiksel algoritmalar, özellikler üzerindeki minimum ve maksimum değerler veya bireysel kümelerin ortalama değerleri veya sınıfların her biri için ortalama ve varyans kovaryans matrisleri gibi eğitim sınıfları biçiminde örnek verilerden türetilmiş parametreleri kullanmaktadır. Yapay sinir ağı gibi istatistiksel olmayan yöntemler, örnek veriden türetilen istatistiksel bilgilere dayanmaz, ancak örnek veriler üzerinde doğrudan eğitilir. Buna karşılık, maksimum olasılık (ML) prosedürü gibi istatistiksel yöntemler, her sınıf için frekans dağılımının formda çok değişkenli olduğu varsayımına dayanır. Böylece, istatistiksel yöntemlerin parametrik olduğu söylenir (çünkü eğitim verilerinden türetilen istatistiksel parametrelerin tahminlerini kullanırlar), oysa sinirsel yöntemler parametrik değildir. Bu çalışmada, Kontrollü sınıflandırmanın iki yöntemini ele alacağız(Destek Vektör Makineleri ve yapay sinir ağları)[4].

2.2.1. Destek Vektör Makineleri

İki sınıf durumunda, bir destek vektör sınıflandırıcısı bir hiper planı bulmaya çalışır Bu, her sınıfın üyelerinden optimum hiperdüzlemine kadar olan mesafeyi en üst düzeye çıkarır[11]. Destek vektör makineleri (DVM) istatistiksel öğrenme teorisine dayalı parametrik olmayan bir sınıflandırma yöntemidir (Vapnik, 1995). DVM, az sayıda veri ile kullanıldığında görüntü sınıflandırmasında doğru sonuçlar elde edilmiştir (Foody ve Mathur, 2004). DVM uzayda sınıflar arasındaki sınırı belirlemek için ideal bir algoritmadır. Başlangıçta DVM, iki sınıflı doğrusal verileri sınıflandırmak ve daha sonra çoklu ve doğrusal olmayan sınıflar için sınıflandırmak üzere tasarlanmıştır[12].


2.2.1.1. Doğrusal Ayrılabilen Veriler için DVM

$\{-1, +1\}$ olarak etiketlenen iki sınıfı sınıflandırmak için en iyi eğitim verilerini ayıran bir hiper-düzlem kullanılmıştır. İki sınıf veriyi ayırt edebilen bir çok hiperdüzlem çizilebilir. ancak DVM'nin amacı, kendine en yakın noktalar arasındaki mesafeyi en yükseğe çıkaran bu hiperdüzlemler arasında en iyi olanı bulmaktır. Hiperdüzlemi ve sınır genişliğini sınırlayan noktalara destek vektörleri denir. Şekil (2.3a, 2.3b)'da gösterildiği. DVM eğitimi için k örnek sayısının eğitim verisinin $\{x_i, y_i\}$, $i = 1, \dots, k$ olduğu varsayıldığında, iki sınıf arasında doğrusal olarak ayrılabiliriz, optimum hiper düzlem ile ilgili eşitsizlikler aşağıdaki gibidir:


$$w \cdot x_i + b \geq 1 \text{ her } y=+1 \text{ için (2)}$$

$$w \cdot x_i + b \leq -1 \text{ her } y=-1 \text{ için (3)}$$

Burada $x \in \mathbb{R}^N$ olup N -boyutlu bir uzayı, $y \in \{-1, +1\}$ ise sınıf etiketlerini, w ağırlık vektörünü (hiper-düzlemin normali) ve b eğilim değerini göstermektedir (Osuna vd., 1997). optimum hiperplane'i bulmak için düzlemi paralel olmalı ve sınır oluşturacak şekilde iki hiperdüzlem tanımlanmalıdır[13].




(a)



(b)


Şekil 2.3. (a) İki sınıflı bir problem için hiper-düzlemler, 2.3 (b) Optimum hiper-düzlem ve destek vektörleri[13].



Şekil 2.4. Doğrusal olarak ayrılabilen veri setleri için hiper-düzlemin belirlenmesi[13].

Örneğin; Burada başlamak için 3 Destek Vektörü seçiyoruz. Bunlar S1, S2 ve S3'tür.

$$S1 = \begin{pmatrix} 2 \\ 1 \end{pmatrix}, S2 = \begin{pmatrix} 2 \\ -1 \end{pmatrix}, S3 = \begin{pmatrix} 4 \\ 0 \end{pmatrix}$$



Şekil 2. 5 Doğrusal Ayrılabilen Veriler için DVM [14].

Burada bir eğilim girişi olarak 1 ile arttırılmış vektörleri kullanacağız

$$S1 = \begin{pmatrix} 2 \\ 1 \\ 1 \end{pmatrix}, S2 = \begin{pmatrix} 2 \\ -1 \\ 1 \end{pmatrix}, S3 = \begin{pmatrix} 4 \\ 0 \\ 1 \end{pmatrix}$$

Şimdi aşağıdaki 3 doğrusal denklemi temel alarak α_1 , α_2 ve α_3 parametrelerini bulmamız gerekiyor:

$$\alpha_1 \tilde{S}_1 \cdot \tilde{S}_1 + \alpha_2 \tilde{S}_2 \cdot \tilde{S}_1 + \alpha_3 \tilde{S}_3 \cdot \tilde{S}_1 = -1 \text{ (-ve class)}$$

$$\alpha_1 \tilde{S}_1 \cdot \tilde{S}_2 + \alpha_2 \tilde{S}_2 \cdot \tilde{S}_2 + \alpha_3 \tilde{S}_3 \cdot \tilde{S}_2 = -1 \text{ (-ve class)}$$

$$\alpha_1 \tilde{S}_1 \cdot \tilde{S}_3 + \alpha_2 \tilde{S}_2 \cdot \tilde{S}_3 + \alpha_3 \tilde{S}_3 \cdot \tilde{S}_3 = +1 \text{ (+ve class)}$$

Yukarıdaki denklemlerde S_1 , S_2 ve S_3 değerlerini değiştirelim.

$$\alpha_1 \begin{pmatrix} 2 \\ 1 \\ 1 \end{pmatrix} \cdot \begin{pmatrix} 2 \\ 1 \\ 1 \end{pmatrix} + \alpha_2 \begin{pmatrix} 2 \\ -1 \\ 1 \end{pmatrix} \cdot \begin{pmatrix} 2 \\ 1 \\ 1 \end{pmatrix} + \alpha_3 \begin{pmatrix} 4 \\ 0 \\ 1 \end{pmatrix} \cdot \begin{pmatrix} 2 \\ 1 \\ 1 \end{pmatrix} = -1$$

$$\alpha_1 \begin{pmatrix} 2 \\ 1 \\ 1 \end{pmatrix} \cdot \begin{pmatrix} 2 \\ -1 \\ 1 \end{pmatrix} + \alpha_2 \begin{pmatrix} 2 \\ -1 \\ 1 \end{pmatrix} \cdot \begin{pmatrix} 2 \\ -1 \\ 1 \end{pmatrix} + \alpha_3 \begin{pmatrix} 4 \\ 0 \\ 1 \end{pmatrix} \cdot \begin{pmatrix} 2 \\ -1 \\ 1 \end{pmatrix} = -1$$

$$\alpha_1 \begin{pmatrix} 2 \\ 1 \\ 1 \end{pmatrix} \cdot \begin{pmatrix} 4 \\ 0 \\ 1 \end{pmatrix} + \alpha_2 \begin{pmatrix} 2 \\ -1 \\ 1 \end{pmatrix} \cdot \begin{pmatrix} 4 \\ 0 \\ 1 \end{pmatrix} + \alpha_3 \begin{pmatrix} 4 \\ 0 \\ 1 \end{pmatrix} \cdot \begin{pmatrix} 4 \\ 0 \\ 1 \end{pmatrix} = +1$$

Sadeleştirmeden sonra şunu elde ederiz:

$$6\alpha_1 + 4\alpha_2 + 9\alpha_3 = -1$$

$$4\alpha_1 + 6\alpha_2 + 9\alpha_3 = -1$$

$$9\alpha_1 + 9\alpha_2 + 17\alpha_3 = +1$$

Elde ettiğimiz yukarıdaki 3 eşitliğin basitleştirilmesi:

$$\alpha_1 = \alpha_2 = -3.25 \text{ and } \alpha_3 = 3.5$$

Pozitif sınıfı negatif sınıftan ayıran hiper düzlem şu şekildedir:

$$\tilde{w} = \sum_i \alpha_i S_i$$


Elde ettiğimiz değerlerin yerine koymak:

$$\tilde{w} = \alpha_1 \begin{pmatrix} 2 \\ 1 \\ 1 \end{pmatrix} + \alpha_2 \begin{pmatrix} 2 \\ -1 \\ 1 \end{pmatrix} + \alpha_3 \begin{pmatrix} 4 \\ 0 \\ 1 \end{pmatrix}$$

$$\tilde{w} = (-3.25) \cdot \begin{pmatrix} 2 \\ 1 \\ 1 \end{pmatrix} + (-3.25) \cdot \begin{pmatrix} 2 \\ -1 \\ 1 \end{pmatrix} + (3.5) \cdot \begin{pmatrix} 4 \\ 0 \\ 1 \end{pmatrix} = \begin{pmatrix} 1 \\ 0 \\ -3 \end{pmatrix}$$

Bu nedenle ayırıcı hiper düzlem denklemi[14].

$y = wx + b$ ile $w = \begin{pmatrix} 1 \\ 0 \end{pmatrix}$ ve ofset $b = -3$



Şekil 2.6. Doğrusal Ayrılabilen Veriler için DVM [14].

Bu doğrusal destek vektör makinelerinin beklenen karar yüzeyidir.

2.2.1.2. Doğrusal Ayrılamayan Veriler için DVM

Görüntü sınıflandırması gibi bir çok problemde, veriyi şekil (2.7a) 'de gösterildiği gibi doğrusal olarak ayırmak olanaksızdır. Bu durumda eğitim verilerinin bir kısmının optimum hiper-düzlemin diğer tarafında kalmasından kaynaklanan problem pozitif bir yapay değişkenin (ξ) tanımlanması ile çözülür [Şekil 2.7b]. yanlış sınıflandırma hatalarını en aza indirmek ve sınırı maksimize etmek, regresyon parametresini ($0 < c < \infty$) tanımlamak suretiyle kontrol edilmiştir; burada c , pozitif değerleri temsil etmektedir (Cortes vd., 1995). Doğrusal olmayan ayırıcı için optimizasyon problemi düzenleyici parametre ve yapay değişken kullanılarak çözülmüştür:

$$\min \left[\frac{\|w\|^2}{2} + c \cdot \sum_{i=1}^r \xi_i \right] (4)$$



şeklini alır.

Buna bağlı sınırlamalar ise;


$$Y_i(w \cdot \phi(x_i) + b) - 1 \geq 1 - \xi_i (5)$$

$$\xi_i \geq 0 \text{ ve } i = 1, \dots, N (6)$$

şeklinde ifade edilir.




Şekil 2.7. (a) Doğrusal olarak ayrılamayan veri seti, 2.7 (b) Doğrusal ayrılamayan veri setleri için hiper-düzlemin belirlenmesi. Doğrusal olarak ayrılmayan verilerin sorunlarını çözmek için verilerin yüksek boyutlu bir alanda görüntülenmesi gerekir. Bu durumda, (2.7c) 'de gösterildiği gibi hiper düzlemi belirleyebiliriz [13].



Şekil 2.7c Kernel fonksiyonu ile verinin daha yüksek bir boyuta dönüştürülmesi[13].

Örneğin; Burada, aşağıda verilen gibi bir örneğe bakacağız ve sınıflandırmayı nasıl yürütüleceğini bulacağız (2.8) 'de gösterildiği gibi. kırmızı sınıf ile mavi sınıf arasında kesin bir ayırıcı hiperplane yoktur.



Şekil 2.8. Doğrusal Ayrılamayan Veriler için DVM [14].

- Mavi sınıf vektörleri: $\begin{pmatrix} 1 \\ 1 \end{pmatrix}, \begin{pmatrix} -1 \\ 1 \end{pmatrix}, \begin{pmatrix} -1 \\ -1 \end{pmatrix}, \begin{pmatrix} 1 \\ -1 \end{pmatrix}$
- Kırmızı sınıf vektörleri: $\begin{pmatrix} 2 \\ 0 \end{pmatrix}, \begin{pmatrix} 0 \\ 2 \end{pmatrix}, \begin{pmatrix} -2 \\ 0 \end{pmatrix}, \begin{pmatrix} 0 \\ -2 \end{pmatrix}$

-Burada doğrusal olmayan bir haritalama fonksiyonu Φ bulmalıyız ki bu da bu verileri ayrı bir hiper düzlemin bulunabileceği yeni bir özellik alanına dönüştürebilir. Aşağıdaki haritalama işlevini düşünelim. Şimdi mavi ve kırmızı sınıf vektörlerini doğrusal olmayan haritalama fonksiyonu Φ kullanarak dönüştürelim.

$$\Phi \begin{pmatrix} X_1 \\ X_2 \end{pmatrix} = \begin{cases} \begin{pmatrix} 6-X_1+(X_1-X_2)^2 \\ 6-X_2+(X_1-X_2)^2 \end{pmatrix} & \text{eğer } \sqrt{X_1^2 + X_2^2} \geq 2 \end{cases}$$

- Mavi sınıfı vektörleri: $\begin{pmatrix} 1 \\ 1 \end{pmatrix}, \begin{pmatrix} -1 \\ 1 \end{pmatrix}, \begin{pmatrix} -1 \\ -1 \end{pmatrix}, \begin{pmatrix} 1 \\ -1 \end{pmatrix}$; değerleri $\sqrt{X_1^2 + X_2^2} < 2$ denkleminde yazınca < 2 geldi. Dolayısıyla $\Phi \begin{pmatrix} X_1 \\ X_2 \end{pmatrix} = \begin{cases} \begin{pmatrix} 6-X_1+(X_1-X_2)^2 \\ 6-X_2+(X_1-X_2)^2 \end{pmatrix} \end{cases}$ kullanılmaz. Tüm vektörler için geçerlidir.


Red sınıfı vektörlerini alalım: $\begin{pmatrix} 2 \\ 0 \end{pmatrix}, \begin{pmatrix} 0 \\ 2 \end{pmatrix}, \begin{pmatrix} -2 \\ 0 \end{pmatrix}, \begin{pmatrix} 0 \\ -2 \end{pmatrix}$

$$\Phi \begin{pmatrix} X_1 \\ X_2 \end{pmatrix} = \Phi \begin{pmatrix} 2 \\ 0 \end{pmatrix} = \begin{pmatrix} 6-2+(2-0)^2 \\ 6-0+(2-0)^2 \end{pmatrix} = \begin{pmatrix} 8 \\ 10 \end{pmatrix}$$

$$\Phi \begin{pmatrix} X_1 \\ X_2 \end{pmatrix} = \Phi \begin{pmatrix} 0 \\ 2 \end{pmatrix} = \begin{pmatrix} 6-0+(0-2)^2 \\ 6-2+(0-2)^2 \end{pmatrix} = \begin{pmatrix} 10 \\ 8 \end{pmatrix}$$

$$\Phi \begin{pmatrix} X_1 \\ X_2 \end{pmatrix} = \Phi \begin{pmatrix} -2 \\ 0 \end{pmatrix} = \begin{pmatrix} 6+2+(-2-0)^2 \\ 6-0+(-2-0)^2 \end{pmatrix} = \begin{pmatrix} 12 \\ 10 \end{pmatrix}$$


$$\Phi \begin{pmatrix} X_1 \\ X_2 \end{pmatrix} = \Phi \begin{pmatrix} 0 \\ -2 \end{pmatrix} = \begin{pmatrix} 6-0+(0+2)^2 \\ 6+2+(0+2)^2 \end{pmatrix} = \begin{pmatrix} 10 \\ 12 \end{pmatrix}$$



Şekil 2.9. Doğrusal Ayrılamayan Veriler için DVM [14].

Şimdi görevimiz bu iki sınıfı sınıflandırmak için uygun destek vektörlerini bulmaktır.

Şekil (2.10) 'de aşağıdaki 3 destek vektörünü seçeceğiz: $S1 = \begin{pmatrix} 8 \\ 10 \end{pmatrix}$, $S2 = \begin{pmatrix} 10 \\ 8 \end{pmatrix}$, $S3 = \begin{pmatrix} 1 \\ 1 \end{pmatrix}$



Şekil 2.10. Doğrusal Ayrılamayan Veriler için DVM [14].

-Burada eğilim girişi olarak 1 ile arttırılmış vektörleri kullanacağız.

$$S1=\begin{pmatrix} 8 \\ 10 \\ 1 \end{pmatrix}, S2=\begin{pmatrix} 10 \\ 8 \\ 1 \end{pmatrix}, S3 = \begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix}$$

-Şimdi aşağıdaki 3 doğrusal denklemi temel alarak α_1 , α_2 ve α_3 parametrelerini bulmamız gerekiyor:

$$\alpha_1 \tilde{S}_1 \cdot \tilde{S}_1 + \alpha_2 \tilde{S}_2 \cdot \tilde{S}_1 + \alpha_3 \tilde{S}_3 \cdot \tilde{S}_1 = +1 \text{ (+ve class)}$$

$$\alpha_1 \tilde{S}_1 \cdot \tilde{S}_2 + \alpha_2 \tilde{S}_2 \cdot \tilde{S}_2 + \alpha_3 \tilde{S}_3 \cdot \tilde{S}_2 = +1 \text{ (+ve class)}$$

$$\alpha_1 \tilde{S}_1 \cdot \tilde{S}_3 + \alpha_2 \tilde{S}_2 \cdot \tilde{S}_3 + \alpha_3 \tilde{S}_3 \cdot \tilde{S}_3 = -1 \text{ (-ve class)}$$

Yukarıdaki denklemlerde S1, S2 ve S3 değerlerini değiştirelim.

$$\alpha_1 \begin{pmatrix} 8 \\ 10 \\ 1 \end{pmatrix} \cdot \begin{pmatrix} 8 \\ 10 \\ 1 \end{pmatrix} + \alpha_2 \begin{pmatrix} 10 \\ 8 \\ 1 \end{pmatrix} \cdot \begin{pmatrix} 8 \\ 10 \\ 1 \end{pmatrix} + \alpha_3 \begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix} \cdot \begin{pmatrix} 8 \\ 10 \\ 1 \end{pmatrix} = +1$$

$$\alpha_1 \begin{pmatrix} 8 \\ 10 \\ 1 \end{pmatrix} \cdot \begin{pmatrix} 10 \\ 8 \\ 1 \end{pmatrix} + \alpha_2 \begin{pmatrix} 10 \\ 8 \\ 1 \end{pmatrix} \cdot \begin{pmatrix} 10 \\ 8 \\ 1 \end{pmatrix} + \alpha_3 \begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix} \cdot \begin{pmatrix} 10 \\ 8 \\ 1 \end{pmatrix} = +1$$

$$\alpha_1 \begin{pmatrix} 8 \\ 10 \\ 1 \end{pmatrix} \cdot \begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix} + \alpha_2 \begin{pmatrix} 10 \\ 8 \\ 1 \end{pmatrix} \cdot \begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix} + \alpha_3 \begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix} \cdot \begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix} = -1$$

- Çarpma işleminden sonra:

$$165\alpha_1 + 161\alpha_2 + 19\alpha_3 = +1$$

$$161\alpha_1 + 165\alpha_2 + 19\alpha_3 = +1$$

$$19\alpha_1 + 19\alpha_2 + 3\alpha_3 = -1$$

-Elde ettiğimiz yukarıdaki 3 eşit eşitliğin basitleştirilmesi: $\alpha_1 = \alpha_2 = 0.859$ and

$$\alpha_3 = -1.4219.$$

-Pozitif sınıfı negatif sınıftan ayıran hiper düzlem verilir tarafından:

$$\tilde{w} = \sum_i \alpha_i S_i$$

Elde ettiğimiz değerlerin yerine koymak:


$$\tilde{w} = \alpha_1 \begin{pmatrix} 8 \\ 10 \\ 1 \end{pmatrix} + \alpha_2 \begin{pmatrix} 10 \\ 8 \\ 1 \end{pmatrix} + \alpha_3 \begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix} =$$

$$\tilde{w} = (0.0859) \cdot \begin{pmatrix} 8 \\ 10 \\ 1 \end{pmatrix} + (0.0859) \cdot \begin{pmatrix} 10 \\ 8 \\ 1 \end{pmatrix} + (-1.4219) \cdot \begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix} = \begin{pmatrix} 0.1243 \\ 0.1243 \\ -1.2501 \end{pmatrix}$$

-Vektörlerimize eğilimle eklenmiştir. Bu nedenle ayırıcı hiper düzlem denklemi

$$Y = WX + b \rightarrow W = \begin{pmatrix} 0.1243 \\ 0.1243 \\ 0.1243 \\ 0.1243 \end{pmatrix} = \begin{pmatrix} 1 \\ 1 \end{pmatrix}$$

ve ofset $b = -1.2501/0.1243 = -10.057$



Şekil 2.11. Doğrusal Ayrılamayan Veriler için DVM [14].


$$y = wx + b$$

$$w = \begin{pmatrix} 1 \\ 1 \end{pmatrix} \text{ ve ofset}$$

$$b = -10.057 [14].$$

2.2.2. Yapay Sinir Ağları ile görüntü sınıflandırması.

Yapay sinir ağları (ANN), girdi verileri ve çıktı verileri arasındaki bağlantıların kurulması ve takviye edilmesi yoluyla insan öğrenme süreçlerini taklit etmek üzere tasarlanmış bilgisayar programlarıdır[1]. Sahip olduğumuz en iyi görüntü-yorumlama sistemi, gözlerimizin ve beynimizin kombinasyonudur. İki algılayıcı (gözlerimiz) tarafından alınan sinyaller, elektriksel uyarılara dönüştürülür ve bunları gerçek zamanlı olarak yorumlayan beyine aktarılır ve böylece görüş alanımızda etiketli üç boyutlu görüntüler üretilir[4]. Bir nöron beyindeki bir hücredir; ana fonksiyonu, elektrik sinyallerinin toplanması, işlenmesi ve yayılmasıdır. sinir ağları, zor sınıflandırma ve optimizasyon problemlerini çözmek için birlikte çalışan çok sayıda küçük ve birbirine bağlı işlemci veya nöral olan insanların düşünme sürecini taklit eder. Sinir ağları, ağdaki nöronları birbirine bağlayan ağırlıkların ayarlanmasına dayalı yapılandırılmamış bir modele göre adım adım algoritma veya karmaşık bir mantıksal program yoluyla değil bir çözüme ulaşır. sinir ağları, algoritmik olmayan. Sinir ağları, çeşitli uzaktan algılayıcı verilerini sınıflandırmak için kullanılmıştır ve bazı durumlarda, geleneksel istatistiksel sınıflandırma yöntemlerinden üstün sonuçlar üretmiştir [8]. Şekil 2.12'de temel bir ağ gösterilmektedir. Bu ağ üç katmana sahiptir; giriş katmanı, orta katman (veya "gizli") katmanı ve çıktı katmanı, her düğümde işleme elemanları içerir [2].



Şekil 2.12. Yapay Sinir Ağları[8].

Sinir ağı yönteminin avantajları olmasına rağmen, daha fazla eğitim süresi gerektirmesi, en etkili ağ yapısının belirlenmesi ve sınıflandırma doğruluğunun parametre değişikliklerine duyarlı olması gibi dezavantajları vardır. Uydu görüntüsü için


günümüze kadar başarılı bir sınıflandırma elde etmek için birçok öğrenme algoritması ve yapay sinir ağı modeli geliştirilmiştir. Öz Düzenleyici Haritalar çok katmanlı perseptron (ÇKP) ve radyal tabanlı ağlar (RBF Radial Basis Function) gibi [3].

2.3. Nesne tabanlı Görüntü Sınıflandırması


Bu sınıflandırmaya segmentasyon tabanlı analiz adı da verilir. Her pikseli ayrı ayrı ve sadece spektral bilgiye dayanarak sınıflandırmaya çalışmak yerine, nesne yönelimli analiz, bir görüntüyü alanlara, ağaçlara, binalara vb. Karşılık gelen spektral homojen segmentlere böler. Görsel görüntü yorumunun bilişsel yaklaşımına benzer - her bir unsuru, spektral görünümü açısından değil, aynı zamanda şekli ve dokusu açısından da değerlendirdiğimiz, ve kendi ortamında - OOA'da (object oriented analysis), segmentasyon sürecinde çıkarılan nesneleri sınıflandırmak için bağlamsal ilişkileri ve daha karmaşık segment özelliklerini belirleyebiliriz. Örneğin, iki spektruma benzer orman türünü ayırt etmek için nesne dokusunu kullanabiliriz, ya da bir yüzme havuzunu şeklini ve belki de toprak ve bitki örtüsü yerine çevredeki betonu göz önünde bulundurarak bir göletten ayırmak gibi[6]. Algoritmalar tipik olarak görüntü bölütleme adımında hem spektral hem de mekansal bilgileri birleştirir. Sonuç, şekil ve spektral homojenliğe sahip bireysel alanlar olarak tanımlanan görüntü nesnelerinin oluşturulmasıdır(Benz,2001;Blaschke,2010; Blaschke et al., 2014). Birçok durumda, çıkarılan görüntü nesneleri, görüntü sınıflandırması için daha fazla sayıda anlamlı özellik sağlayabilmektedir. Nesne, herhangi bir mekansal dağılımlı değişkenden de geliştirilebilir(örneğin, yükseklik, eğim, görünüm, popülasyon yoğunluğu). Homojen görüntü nesnesi daha sonra geleneksel sınıflandırma algoritmaları kullanılarak analiz edilir (örneğin, minimum mesafe, maksimum olabilirlik). Görüntü nesnelerini bölmek için kullanılabilecek birçok algoritma mevcuttur. Çoğu, iki sınıfa ayrılabilir: kenar tabanlı algoritmalar ve alan tabanlı algoritmalar. Ne yazık ki çoğunluk hem spektral hem de mekansal bilgiyi birleştirmez ve uzaktan algılama dijital görüntü sınıflandırması için çok azı kullanılmıştır. Uzaktan algılama görüntü segmentasyonuna çok önemli bir yaklaşım, Baatz ve Schape (2000) tarafından geliştirilmiştir. Görüntü segmentasyonu, renk kriterini (h rengi) ve şekil veya mekansal kriteri (h şekli) hesaplamak için bireysel piksel değerlerine ve komşularına bakmayı içerir(Baatz et al.,2001). Bu iki kriter daha sonra genel segmentasyon fonksiyonları (Sf) kullanılarak uzaktan algılama veri setinde

nispeten homojen piksellerin görüntü nesnelerini (parçalar) oluşturmak için kullanılır [8]. Kullanıcı, şekle karşı spektral renk için bir ağırlık tanımlamıştır $0 \leq w_{color} \leq 1$


$$S_f = w_{color} \cdot h_{color} + (1 - w_{color}) \cdot h_{shape}(7)$$




Şekil 2.13. Görüntü segmentasyonu (ölçek 100)



Şekil 2.14. Görüntü segmentasyonu (ölçek 75)



Şekil 2.15. Görüntü segmentasyonu (ölçek 50)



Şekil 2.16. Görüntü segmentasyonu (ölçek 25)

2.4. Uzaktan Algılama Uyduları

Birçok şirket ve ulusal hükümetler, Dünya yüzeyinin gözlenmesi için özel bir uydu uzaktan algılama sistemi tasarladılar. bu sistemler, bitki, orman, su gövdeleri, arazi kullanımı, şehirler ve mineraller gibi konuları ilgilendiren toprak yüzeyi hakkında bilgi toplamayı amaçlamaktadır. Uydu sensörleri, alanların izlenmesi), iyi detay ve tekrarlayan kapsama alanı sağlar. bu yetenekler çok önemlidir ve dünyanın günümüzde yüzyüze gelebildiği birçok geniş ölçekli çevresel değişimi izlemek için uygundur. çünkü kullanılan çok sayıda uydu gözlem sistemi ve hızlı tasarımlarındaki değişiklikleri, şu anda kullanımda olan veya planlanan tüm sistemleri açıklayamayız. Bununla birlikte, belirli uydu sistemleri hakkında bilgi edinmek için Dünya gözlem uydularının genel özelliklerini anlamak için ihtiyaç duydukları temel çerçeve bu bölümde açıklanmıştır [1].

2.4.1. LANDSAT Uydu Sistemi

Landsat, 1960'da tasarlanmış ve 1972'de, Dünya'nın geniş ölçekli gözlemleri için özel olarak yapılmış ilk uydu olarak başlatılmıştır. benzer arazi gözlem uydularına giriş olarak

düşünülür, çünkü bu, bu alandaki çalışmalara büyük ölçüde katkıda bulunmuştur. Landsat 1,2 ve 3, iki sensör taşıyan operasyonlarında çok benzer oldukları için birinci kuşaktır. Bu sensörler: Return Beam Vidicon (RBV) kamera ve Multispectral Scanner (MSS).

Landsat 1,2 ve 3 kelebek biçimli sistemler yaklaşık 3m uzunluğunda ve 1.5m çapındaydı ve yaklaşık 815kg ağırlığında 900 km nominal irtifada dairesel yörüngede hizmet vermektedir.1982 yılında başlatılan Landsat 4, RBV yerine Thematic Mapper (TM) ile sağlandı. Landsat 5,6 ve 7, sırasıyla 1984,1993,1999'da fırladılar.Landsat uydusu, güneşe senkronize, dairesel,tekrarlı, kutuplara-yakın yörüngeye sahiptir. Landsat 1-Landsat 7'nin özellikleri tablo 2.1'de gösterildiği şekildedir. [5].

Tablo 2.1. Landsat özellikleri

Uydu	Sensör Tipi	Çözünürlük			
		Spektral (μm)	Yersel (m)	Radyometrik (bit)	Zamansal gün
Landsat 1/2/3	MSS	VNIR: 0.5–0.6, 0.6–0.7, 0.7–0.8, 0.8–0.11	79	6	18
Landsat 4/5	TM	V VNIR: 0.45–0.52, 0.52–0.60, 0.63–0.69, 0.76–0.90. SWAR:1.55-1.75,2.08-2.35 TIR: 10.42–12.5	30 30 120	8	16
Landsat 7	PAN ETM	0.52–0.9 VNIR ve SWIR Landsat 5 ile aynı TIR: 10.42–12.5	15 30 60	8	16
Landsat 8	OLI TIS	VNIR: 0.433- 1.390 μm TIRS 1 (10.3 - 11.3 μm) TIRS 2 (11.5 - 12.5 μm)	30 100 100	12	16

2.4.2. TERRA Uydu Sistemi

Sonradan Terra olarak adlandırılan ve 1999'da fırlatılan DGS AM-1(Dünya Gözlem Sistemi) NASA'nın dünya bilimi görevnin odak noktasıdır. İlimli Çözünürlük Görüntüleme Spektrometresi (MODIS) ve İleri Uydu üzerinde Termal Emisyon ve Yansıtıcı Radyometresi (ASTER) de dahil olmak üzere beş uzaktan algılama aleti taşıyor. ASTER enstrümanı, görünür ve yakın kızıl ötesi spektral aralığında üç bant 15 m çözünürlüklü, kısa dalga kızılötesindeki altı bant 30 m çözünürlüklü ve termal kızılötesindeki 90 m çözünürlüklü beş bant ile tasarlanmıştır. Terra misyonuna ek olarak, NASA iki önemli uyduları geliştirdi: Aqua ve Aura denir. Terra esas olarak arazi uygulamaları üzerine odaklanmıştır. Aqua ise suya ve Aura, atmosferdeki gazlara

odaklanır (özellikle ozon). Aşağıdaki 2.2 tabloda Terra ASTER özellikleri gösterilmektedir.

Tablo 2.2.Terra özellikleri

Uydu	Sensör Tipi	Çözünürlük			
		Spektral (µm)	Yersel (m)	Radyometrik (bit)	Zamansal gün
Terra/ ASTER	VNIR	0.52–0.60,0.63–0.69, 0.76–0.86	15	8	16
	SWIR	1.60–1.70, 2.145–2.185, 2.185–2.225, 2.235–2.285, 2.295–2.365, 2.360–2.430	30	8	
	TIR	10.95–11.65	90	12	

2.4.3.SPOT Uydu Sistemi.

SPOT-1, SPOT-2 ve SPOT 3, dairesel, polar yakın güneş senkron yörüngesine sahiptir. spot-1, 1982'de başlatılan programda ilk uydu idi. SPOT-1, SPOT-2 ve SPOT 3, 832 km'lik bir yüksekliğe ve 98.7 derece eğimliye sahiptir. SPOT, yaklaşık 11.00 AM'de 40 N enleminde ve 10.00 A. M'de 40 S enleminde alanları geçmektedir. Aşağıdaki 1.3 tabloda SPOT özellikleri gösterilmektedir.

Tablo 2.3. Spot özellikleri

Uydu	Sensör Tipi	Çözünürlük			
		Spektral (µm)	Yersel (m)	Radyometrik (bit)	Zamansal gün
SPOT 1,2,3	PAN	0.51–0.73	10	8	26
	HRV	VNIR:0.50–0.59, 0.61–0.68, 0.79–0.89	20	8	
SPOT 4	PAN	0.61–0.68	10	8	
	HRV	VNIR:0.50–.59,0.61-0.68, 0.79-0.89	20	8	
	Vejetasyon	SWAR:1.58–1.75, 0.43–0.47, 0.61–0.68 0.78–0.89, 1.58–1.75	1000	4/8	
	Vejetasyon	0.43–0.47, 0.61–0.68, 0.78–0.89, 1.58–1.75	1000	4/8	
SPOT 5	PAN	0.49–0.69	2.5-5	8	26
	HRG	VNIR:0.49-0.61,0.61-0.68, 0.78-0.89.	10	8	
	HRG	SWIR: 1.58–1.75	20	8	
SPOT 5	Vejetasyon	0.43–0.47, 0.61–0.68, 0.78–0.89, 1.58–1.75	1000	4/8	26
	Vejetasyon	0.43–0.47, 0.61–0.68, 0.78–0.89, 1.58–1.75	1000	4/8	

3. BÖLÜM

UYGULAMA VE BULGULAR

3.1. Kullanılan Veri ve Yazılımlar

Bu tez çalışmasında, BAQUBAH bölgesi arazi örtüsünün ve kullanım türlerinin belirlenmesi amacıyla bölgeye ait uydu görüntüleri piksel tabanlı yapay sinir ağları, destek vektör makineleri ve nesne tabanlı yöntemlerle sınıflandırılmıştır.

Baqubah şehrine ait, 2014 yılı Geo-eye uydusundan elde edilen yüksek çözünürlüklü görüntü, ve <http://earthexplorer.usgs.gov> adresinden indirilen Landsat 8 uydu görüntüsü kullanılmıştır. Görüntülerin özellikleri Tablo 3.1’de gösterilmiştir.

Piksel tabanlı yöntemler için Envi 5.3 yazılımı ve nesne tabanlı yöntem için eCognition developer yazılımı kullanılmıştır.

Tablo 3.1. Kullanılan uydu görüntüleri ve özellikleri.

Görüntü	Boyut	Mekansal Çözünürlük	Spektral Bant Sayısı	Sınıf Sayısı
Landsat8	680×1296 piksel	30m	11	4
Geo-eye	14062×14063piksel	0,5m	4	4
çalışma alanı =49588 km ²				



Şekil 3.1. Sınıflandırmada kullanılan Landsat görüntüsü



Şekil 3.2. Sınıflandırmada kullanılan Geo-eye görüntüsü

3.2. Yapay Sinir Ağları ile Görüntü Sınıflandırma

Yapay sinir ağları herhangi bir istatistiksel kabul gerektirmeyen, parametrik olmayan bir kontrolsüz sınıflandırma yöntemidir. YSA eğitimini içeren adımlar şu şekildedir:

- 1-Giriş ve çıkış değerlerinin belirlenmesi.
2. Yapay sinir ağı katmanlarının belirlenmesi.
- 3- Ağ için rastgele bir başlangıç değeri belirlemesi.
- 4- Ağ parametrelerinin belirlenmesi.
- 5- Çıktı kodlamasının belirlenmesi.

Tablo 3.2. Doğruluk matrisi (Landsat görüntüsü)

Sınıflar	Binalar	Bitki Örtüsü	Su	Toprak	Toplam	Doğruluk
Binalar	44	1	0	5	50	88%
Bitki Örtüsü	1	37	10	2	50	74%
Su	1	12	36	1	50	72%
Toprak	9	2	1	38	50	76%
Toplam sütun	55	52	47	46	200	

Sınıflandırılmış haritadan doğruluk oranını test etmek için her sınıftan 50 nokta seçilmiştir ve orjinal haritaya koyulmuştur. Binalar sınıfından seçilen 50 noktadan 44 nokta binalar, 1 nokta bitki örtüsü ve 5 nokta toprak olmak üzere sonuçlar elde edilmiştir. Binalar olarak tespit edilen 44 nokta olduğu için doğruluk oranı yüzde 88 olarak elde edilmiştir. Bitki örtüsü sınıfından seçilen 50 noktadan 37 nokta bitki örtüsü, 1 nokta binalar ve 10 nokta su ve 2 nokta toprak sınıfına ait olmak üzere sonuçlar elde edilmiştir. Bitki örtüsü sınıfına ait 37 nokta olduğu için doğruluk oranı yüzde 74 olarak hesaplanmıştır. Su sınıfından seçilen 50 noktadan 36 nokta su, 1 nokta binalar ve 12 nokta bitki örtüsü ve 1 nokta toprak olarak sınıflandırılmıştır. Su sınıfına ait 36 nokta olduğu için doğruluk oranı yüzde 72 olarak elde edilmiştir. Ve son olarak toprak sınıfından seçilen 50 noktadan 38 noktası toprak, 9 nokta binalar ve 2 nokta bitki örtüsü ve 1 nokta su olmak üzere sınıflandırılmıştır. Toprak sınıfına ait 38 nokta olduğu için doğruluk oranı yüzde 76 olarak elde edilmiştir.

$$\text{Genel doğruluğu} = (44+37+36+38)/(54+52+46+48)$$

$$\text{Genel doğruluğu} = 155/200 = 77.5\%$$

$$N=200$$


$$k = \frac{N \sum_{i=1}^k x_{ii} - \sum_{i=1}^k (GiCi)}{N^2 - \sum_{i=1}^k (GiCi)} \quad (8)$$

$$\sum_{i=1}^k x_{ii} = (44 + 37 + 36 + 38) = 155$$

$$\sum_{i=1}^k (GiCi) = (50 \times 55) + (50 \times 52) + (50 \times 47) + (50 \times 46) = 10000$$

$$K = 200(155) - 10000 / 200^2 - 10000 =$$

Kappa değeri= 0.67 (olasılık matrisiyle sağlanmış bilgiyi özetleyen kappa (κ) katsayısı sınıflandırmanın doğruluğunu ağırlıklı olarak hesaplayan bir istatistiksel ölçü olarak kullanılır. Kappa sayısı 0 ile +1 arasında değişim gösterir. 0 değeri uyumsuzluğu +1 değeri ise pozitif tam uyumu belirtir).



Şekil 3.3. Landsat görüntüsünün YSA ile sınıflandırılması

Tablo 3.3. Doğruluk matrisi (Landsat görüntüsü)

Sınıflar	Binalar	Bitki Örtüsü	Su	Toprak	Toplam	Doğruluk
Binalar	41	1	0	8	50	82%
Bitki Örtüsü	0	37	11	2	50	74%
Su	0	15	32	3	50	60%
Toprak	10	0	0	40	50	80%
Toplam sütun	51	53	43	53	200	

Genel doğruluğu $= (41+37+32+40)/(51+53+43+53)$

Genel doğruluğu $= 150/200 = 75\%$


$N=200$

$$\sum_{i=1}^k x_{ii} = (41 + 37 + 32 + 40) = 150$$

$$\sum_{i=1}^k (G_i C_i) = (50 \times 51) + (50 \times 53) + (50 \times 43) + (50 \times 53) = 10000$$

$$K = 200(150) - 10000 / 200^2 - 10000 =$$

Kappa değeri = 0.63



Şekil 3.4. Landsat görüntüsünün YSA ile sınıflandırılması

Tablo 3.4. Doğruluk matrisi (Geo-eye görüntüsü)

Sınıflar	Binalar	Bitki Örtüsü	Su	Toprak	Toplam	Doğruluk
Binalar	44	0	1	5	50	88%
Bitki Örtüsü	0	43	5	2	50	86%
Su	0	9	41	0	50	82%
Toprak	5	1	0	44	50	88%
Toplam sütun	49	53	47	51	200	

$$\text{Genel doğruluğu} = (44+43+41+44)/(49+53+47+51)$$

$$\text{Genel doğruluğu} = 172/200 = 86\%$$


$$N=200$$

$$\sum_{i=1}^k x_{ii} = (44 + 43 + 41 + 44) = 172$$

$$\sum_{i=1}^k (G_i C_i) = (50 \times 49) + (50 \times 53) + (50 \times 47) + (50 \times 51) = 10000$$

$$K = 200(172) - 10000 / 200^2 - 10000 =$$

$$\text{Kappa değeri} = 0.78$$



Tablo 3.5. Doğruluk matrisi (Geo-eye görüntüsü)

Sınıflar	Binalar	Bitki Örtüsü	Su	Toprak	Toplam	Doğruluk
Binalar	43	1	0	6	50	86%
Bitki Örtüsü	0	38	6	6	50	76%
Su	0	16	32	2	50	64%
Toprak	10	2	0	38	50	76%
Toplam sütun	53	57	38	52	200	

$$\text{Genel doğruluğu} = (43+38+32+38)/(53+57+38+52)$$

Genel doğruluğu = $151/200=75.5\%$


$N=200$

$$\sum_{i=1}^k x_{ii} = (43 + 38 + 32 + 38) = 151$$

$$\sum_{i=1}^k (GiCi) = (50 \times 53) + (50 \times 57) + (50 \times 38) + (50 \times 52) = 10000$$

$$K=200(151)-10000/200^2-10000=$$

Kappa değeri= 0.63



Şekil 3.6. Geo-eye görüntüsünün YSA ile sınıflandırılması

3.3. Destek Vektör Makineleri ile Görüntü Sınıflandırma

Bu yöntem istatistiksel öğrenmeye dayanmaktadır ve daha sonra çok sınıflı verileri sınıflandırmak için tasarlanmıştır. Çoklu sınıflar arasında ayırım yapmak için DVM'nin özelliklerine göre özel bir stratejinin izlenmesi gerekmektedir. Bu sınıflar doğrusal veya doğrusal olmayan olabilir. Verileri doğrusal olarak ayırmak mümkün değildir. Bu nedenle, kernel fonksiyonlarının kullanılması gerekmektedir. Bu tezde Polinom Kerneli, Doğrusal Fonksiyon Kerneli, Doğrusal Fonksiyon Kerneli ve Radyal Tabanlı Fonksiyon Kerneli görüntü sınıflandırmasında yaygın yöntem olarak kullanılmıştır. doğruluk matrisi Tablo 3.6'de gösterilmiştir.

Tablo 3.6. Doğruluk matrisi (Landsat görüntüsü)

Sınıflar	Binalar	Bitki ortusu	Su	Toprak	Toplam	Doğruluk
Binalar	19	0	0	1	20	95%
Bitki ortusu	4	27	0	4	35	77%
Su	2	0	1	0	3	33%
Toprak	9	2	0	31	42	74%
Toplam sütun	34	29	1	36	100	

$$\text{Genel doğruluğu} = (19+27+1+31)/(34+29+1+36)$$

$$\text{Genel doğruluğu} = 78/100 = 78\%$$


$$N=100$$

$$\sum_{i=1}^k x_{ii} = (19 + 27 + 1 + 31) = 78$$

$$\sum_{i=1}^k (G_i C_i) = (20 \times 34) + (35 \times 29) + (3 \times 1) + (42 \times 36) = 3210$$

$$K = 100(78) - 3210 / 100^2 - 3210 = 4590 / 6790$$

$$\text{Kappa değeri} = 0.68$$



Şekil 3.7. Landsat görüntüsünün DVM ile sınıflandırılması

Tablo 3.7. Doğruluk matrisi (Landsat görüntüsü)

Sınıflar	Binalar	Bitki Örtüsü	Su	Toprak	Toplam	Doğruluk
Binalar	42	1	0	7	50	84%
Bitki Örtüsü	0	41	4	5	50	82%
Su	0	11	38	1	50	76%
Toprak	5	3	1	41	50	82%
Toplam sütun	47	56	43	54	200	

$$\text{Genel doğruluğu} = (42+41+38+41)/(47+56+43+54)$$

$$\text{Genel doğruluğu} = 162/200 = 81\%$$


$$N=200$$

$$\sum_{i=1}^k x_{ii} = (42 + 41 + 38 + 41) = 162$$

$$\sum_{i=1}^k (G_i C_i) = (50 \times 47) + (50 \times 56) + (50 \times 43) + (50 \times 54) = 10000$$

$$K = 200(162) - 10000 / 200^2 - 10000 =$$

$$\text{Kappa değeri} = 0.71$$



Şekil 3.8. Landsat görüntüsünün DVM ile sınıflandırılması.

Tablo 3.8. Doğruluk matrisi (Landsat görüntüsü)

Sınıflar	Binalar	Bitki Örtüsü	Su	Toprak	Toplam	Doğruluk
Binalar	43	1	0	6	50	86%
Bitki Örtüsü	0	44	3	3	50	88%
Su	0	13	37	0	50	74%
Toprak	8	2	0	40	50	80%
Toplam sütun	51	60	40	49	200	

$$\text{Genel doğruluğu} = (43+44+37+40)/(51+60+40+49)$$

Genel doğruluğu = $164/200=82\%$


$N=200$

$$\sum_{i=1}^k x_{ii} = (43 + 44 + 37 + 40) = 164$$

$$\sum_{i=1}^k (GiCi) = (50 \times 51) + (50 \times 60) + (50 \times 40) + (50 \times 49) = 10000$$

$$K=200(164)-10000/200^2-10000=$$

Kappa değeri=0.73



Şekil 3.9. Landsat görüntüsünün DVM ile sınıflandırılması.

Tablo 3.9. Doğruluk matrisi (Geo-eye görüntüsü)

Sınıflar	Binalar	Bitki ortusu	Su	Toprak	Toplam	Doğruluk
Binalar	17	0	0	6	23	74%
Bitki ortusu	2	29	0	2	33	87%
Su	2	1	4	0	7	57%
Toprak	7	1	0	29	37	78%
Toplam sütun	28	31	4	37	100	

$$\text{Genel doğruluğu} = (17+29+4+29)/100$$

$$\text{Genel doğruluğu} = 79/100 = 79\%$$


$$N=100$$

$$\sum_{i=1}^k x_{ii} = (17 + 29 + 4 + 29) = 79$$

$$\sum_{i=1}^k (G_i C_i) = (23 \times 28) + (33 \times 31) + (7 \times 4) + (37 \times 37) = 3064$$

$$K = 100(79) - 3064 / 100^2 - 3064 = 4836 / 6936$$

$$\text{Kappa değeri} = 0.7$$



Şekil 3.10. Geo-eye görüntüsünün DVM ile sınıflandırılması.

Tablo 3.10. Doğruluk matrisi (Geo-eye görüntüsü)

Sınıflar	Binalar	Bitki Örtüsü	Su	Toprak	Toplam	Doğruluk
Binalar	43	3	0	4	50	86%
Bitki Örtüsü	0	39	9	2	50	78%
Su	1	14	35	0	50	70%
Toprak	3	0	0	47	50	94%
Toplam sütun	47	56	44	53	200	

Genel doğruluğu $= (43+39+35+47)/(47+56+44+53)$

Genel doğruluğu $= 164/200 = 82\%$


$N=200$

$$\sum_{i=1}^k x_{ii} = (43 + 39 + 35 + 47) = 164$$

$$\sum_{i=1}^k (G_i C_i) = (50 \times 47) + (50 \times 56) + (50 \times 44) + (50 \times 53) = 10000$$

$$K = 200(164) - 10000 / 200^2 - 10000 =$$

Kappa değeri $= 0.73$



Şekil 3.11. Geo-eye görüntüsünün DVM ile sınıflandırılması.

Tablo 3.11. Doğruluk matrisi (Geo-eye görüntüsü).

Sınıflar	Binalar	Bitki Örtüsü	Su	Toprak	Toplam	Doğruluk
Binalar	45	0	0	5	50	90%
Bitki Örtüsü	1	40	7	2	50	80%
Su	0	10	40	0	50	80%
Toprak	3	0	0	47	50	94%
Toplam sütun	49	50	47	54	200	

$$\text{Genel doğruluğu} = (45+40+40+47)/(49+50+47+54)$$

$$\text{Genel doğruluğu} = 172/200 = 86\%$$


$$N=200$$

$$\sum_{i=1}^k x_{ii} = (45 + 40 + 40 + 47) = 172$$

$$\sum_{i=1}^k (G_i C_i) = (50 \times 49) + (50 \times 50) + (50 \times 47) + (50 \times 54) = 10000$$

$$K = 200(172) - 10000 / 200^2 - 10000 =$$

$$\text{Kappa değeri} = 0.78$$



Şekil 3.12. Geo-eye görüntüsünün DVM ile sınıflandırılması.

3.4. Nesne tabanlı Görüntü Sınıflandırması

Tablo 3.12. Doğruluk matrisi (Landsat görüntüsü)

Sınıflar	Binalar	Bitki Örtüsü	Su	Toprak	Toplam	Doğruluk
Binalar	93	2	0	5	100	93%
Bitki Örtüsü	1	95	0	4	100	95%
Su	0	2	46	2	50	92%
Toprak	4	4	0	92	100	92%
Toplam sütun	98	103	46	103	350	

$$\text{Genel doğruluğu} = (93+95+46+92)/(98+103+46+103)$$

$$\text{Genel doğruluğu} = 326/350 = 93\%$$


$$N=350$$

$$\sum_{i=1}^k x_{ii} = (93 + 95 + 46 + 92) = 326$$

$$\sum_{i=1}^k (GiCi) = (100 \times 98) + (100 \times 103) + (50 \times 46) + (100 \times 103) = 32700$$

$$K = 350(326) - 32700 / 350^2 - 32700 =$$

$$\text{Kappa değeri} = 0.9$$



Şekil 3.13. Landsat görüntüsünün Nesne tabanlı ile sınıflandırılması.

Tablo 3.13. Doğruluk matrisi (GEO-EYE görüntüsü)

Sınıflar	Binalar	Bitki Örtüsü	Su	Toprak	Toplam	Doğruluk
Binalar	93	4	1	2	100	93%
Bitki Örtüsü	2	92	6	0	100	92%
Su	1	9	90	0	100	90%
Toprak	1	2	0	97	100	97%
Toplam sütun	97	107	97	99	350	

$$\text{Genel doğruluğu} = (93+92+90+97)/(97+107+97+99)$$

$$\text{Genel doğruluğu} = 372/400 = 93\%$$


$$N=350$$

$$\sum_{i=1}^k x_{ii} = (93 + 92 + 90 + 97) = 372$$

$$\sum_{i=1}^k (G_i C_i) = (100 \times 97) + (100 \times 107) + (100 \times 97) + (100 \times 99) = 40000$$

$$K = 400(372) - 40000 / 400^2 - 40000 =$$

$$\text{Kappa değeri} = 0.9$$



Şekil 3.14. GEO-EYE görüntüsünün Nesne tabanlı ile sınıflandırılması

4. BÖLÜM

SONUÇLAR

Uzaktan algılama, geniş alanları görüntüleme yeteneğinden dolayı farklı disiplinler tarafından yaygın olarak kullanılmaktadır. Uydu görüntüleri için sınıflandırma süreci, görüntüleri yorumlamak için en önemli aşama olarak kabul edilir. Sınıflandırma kontrollü ve kontrolsüz olarak iki şekilde yapılmaktadır. Kontrollü sınıflandırma daha yaygın kullanılır. Çünkü araştırmacıların kendi ihtiyaçlarına göre eğitim alanlarını seçmelerine ve daha gerçekçi sonuçlar üretmelerine izin vermektedir. Sınıflandırma işleminden kaynaklanan sınıfların bilgilerinin doğruluğu, doğrudan sınıflandırma işlemi için seçilen yöntemle ilgilidir. Bu nedenle, çalışmanın niteliğine ve veri durumuna göre kullanılacak yöntemin doğru seçilmesi büyük önem taşımaktadır. Bu çalışmada, Landsat ve Geo eye görüntüleri, YSA ve DVM yöntemlerinin yanı sıra Nesne tabanlı yöntemi ile sınıflandırılmıştır. Yapılan işlemleri sonucunda Landsat görüntüsü ile yapılan sınıflandırma işleminde, Nesne tabanlı yönteminin en yüksek doğruluğu (93%), YSA yönteminin en düşük (77%, 75% parametrelere göre), DVM ise (78%, 81%, 82% linear, Polynomial and Radyal Tabanlı Fonksiyon sırasıyla). Geo eye görüntüsünün sınıflandırılmasında ise, Nesne tabanlı yönteminin en yüksek doğruluğu (93%), YSA yönteminin en düşük (86%, 75% parametrelere göre), DVM ise (79%, 82%, 86% linear, Polynomial and Radyal Tabanlı Fonksiyon sırasıyla). Bu nedenle, gelecekte iyi bir tematik harita elde etmek için yapılan çalışmalarda, bu tezde yüksek beceriler sağladığı için nesneye dayalı sınıflandırma uygulamanızı öneririz.

Tablo 4.1. Tüm yöntemde kullanılan parametreler.

Yöntemler	Landsat görüntüsü		Geo-Eye görüntüsü	
	Kappa	Genel doğruluğu	Kappa	Genel doğruluğu
Yapay Sinir Ağları (Öğrenme Oranı:0.2, Momentum:0.9).	0.67	%77	0.78	%86
Yapay Sinir Ağları (Öğrenme Oranı:0.3, Momentum:0.2).	0.63	%75	0.63	%75
Destek Vektör Makineleri (kernel = Linear).	0.68	%78	0.7	%79
Destek Vektör Makineleri (kernel = Polynomial).	0.71	%81	0.73	%82
Destek Vektör Makineleri (kernel= Radyal Tabanlı Fonksiyon).	0.73	%82	0.78	%86
Nesne tabanlı Sınıflandırma En Yakın Komşu parametre ölçeği (%75)	0.9	%93	0.9	%93

KAYNAKLAR

1. Campbell, J., Wynne, R., 2011. Introduction To Remote Sensing. A Division of Guilford Publications, 667.
2. Schowengerdt, R., 2007. Remote Sensing: Models And Methods For Image Processing. Library of Congress Cataloging-in-Publication Data, 515.
3. Çölkesen, I., 2009. Uzaktan Algılamada İleri Sınıflandırma Tekniklerinin Karşılaştırılması ve Analizi. Gebze Üniversitesi, 153.
4. Mather, P., Koch, M., 2011. Computer Processing of Remotely-Sensed Images. A John Wiley & Sons, Ltd., Publication, 434.
5. Lillesand, T., Kiefer, R., Chipman, J., 2008. Remote Sensing And Image Interpretation. Library of Congress Cataloging-in-Publication Data, 756.
6. Tempfli, K., Kerle, N., Huurneman, G., Janssen, L., 2001. Principles of Remote Sensing. The International Institute for Geo-Information Science and Earth Observation, 591.
7. Bhatta, B., 2010. Analysis Of Urban Growth And Sprawl From Remote Sensing Data. Springer-Verlag Berlin Heidelberg, 172.
8. Jensen, J., 2016. Introductory Digital Image Processing. Pearson education in the United of America, 623.
9. Attaallah, H., 2016. Analyzing And Modelling Of Built-up Lands Growth In Gaza Strip, Palestine Using Remote Sensing and GIS Techniques. Cairo University, 79.
10. Al-doski, J., Mansor, S., Shafri, H., 2013. Image Classification in Remote Sensing. **Journal of Environment and Earth Science**, 141-147.
11. Pal, M., Mather, P., 2003. Support Vector classifiers for Land Cover Classification. Map India 2003 Image Processing & Interpretation, 11.
12. Üstüner, M., Şanlı, F., Balçık, F., Esetlili, M., 2013. Destek Vektör Makineleri Tekniği İle Sınıflandırma : Rapideye Örneği. *Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği VII*, 5.

13. Kavzoğlu, T., Çölkesen, I., 2010. Destek Vektör Makineleri ile Uydu Görüntülerinin Sınıflandırılmasında Kernel Fonksiyonlarının Etkilerinin İncelenmesi. *Harita Dergisi*, 73-82.
14. <http://www.youtube.com/user/homevideotutor>. 2014.
15. Chen, C., Luo, J., Parker, K., 1998. Image Segmentation via Adaptive k-Mean Clustering and Knowledge-Based Morphological Operations with Biomedical Applications. **IEEE Transaction On Image Processing**, 1673-1683.
16. Işık, M., Çamurcu, Y., 2007. K-means, K-medoids Ve Bulanık C-means Algoritmalarının Uygulamalı Olarak Performanslarının Tespiti. **İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi**, 31-45.
17. Sarıman, G., 2011. Veri Madenciliğinde Kümeleme Teknikleri Üzerine Bir Çalışma: K-Means ve K-Medoids Kümeleme Algoritmalarının Karşılaştırılması. **Süleyman Demirel Üniversitesi, Fen Bilimleri Enstitüsü Dergisi**, 192-202.
18. Fırat, M., Dikbaş, F., Koç, A., Güngör, M., 2012. K-Ortalamlar Yöntemi ile Yıllık Yağışların Sınıflandırılması ve Homojen Bölgelerin Belirlenmesi. **İMO Teknik Dergi**, 6037-6050.
19. jian, W., 2012. Study on Segmentation of Color Remote Sensing Image. International Workshop on Information and Electronics Engineering (IWIEE), 3312 – 3316.
20. Balaji, T., 2013. Relational Features of Remote Sensing Image Classification using Effective K-Means Clustering. **International Journal of Advancements in Research & Technology**, 103-107.
21. Demirkan, M., 2014. Kategorik Ve Kategorik Olamayan Verilerden Oluşan Veri Setleri İçin K-ortalama Tabanlı Bir Yaklaşım. *Baykent Üniversitesi*, 74.
22. Ngo, L., Mai, D., Pedrycz, W., 2015. Semi-supervising Interval Type-2 Fuzzy C-Means clustering with spatial information for multi-spectral satellite image classification and change detection. **Computers & Geosciences**, 1-16.

23. Rozenstein, O., Karnieli, A., 2011. Comparison Of Methods For Land-use Classification Incorporating Remote Sensing And GIS Inputs. **Applied Geography**, 533-544.
24. Rawat, J., Kumar, M., 2015. Monitoring Land use/cover Change Using Remote Sensing And GIS Techniques: A Case Study Of Hawalbagh Block, District Almora, Uttarakhand, India. **The Egyptian Journal of Remote Sensing and Space Sciences**, 77-84.
25. Gandhi, M., Parthiban, G., Thummalu, N., A, G., 2015. Ndvi: Vegetation Change Detection Using Remote Sensing And GIS – A Case Study Of Vellore District. **Procedia Computer Science**, 1199 – 1210.
26. Bakr, N., Weindorf, D., Bahnassy, M., Marei, S., El-Badawi, M., 2010. Monitoring Land Cover Changes In a Newly Reclaimed Area Of Egypt Using Multi-Temporal Landsat Data. **Applied Geography**, 592–605.
27. Han, Y., Feng, X., Baci, G., 2013. Variational And PCA Based Natural Image Segmentation. **Pattern Recognition**, 1971–1984.
28. Ng, S., 2017. Principal component analysis to reduce dimension on digital image. **Procedia Computer Science**, 113-119.
29. Erbek, F., Özkan, C., Taberner, M., 2010. Comparison Of Maximum Likelihood Classification Method With Supervised Artificial Neural Network Algorithms For Land Use Activities. **International Journal of Remote Sensing**, 1733-1748.
30. Srivastava, P., Han, D., Rico-Ramirez, M., Bray, M., Islam, T., 2012. Selection Of Classification Techniques For Land Use/Land Cover Change Investigation. **Advances in Space Research**, 1250–1265.
31. Sammouda, R., Adgaba, N., Touir, A., Al-Ghamdi, A., 2014. Agriculture Satellite Image Segmentation Using a Modified Artificial Hopfield Neural Network. **Computers in Human Behavior**, 436–441.
32. Colkesen, I., Kavzoglu, T., Yomralioglu, T., 2015. Uzaktan Algılanmış Görüntülerde Optimum Bantların Seçiminde Destek Vektör Makinelerinin Kullanımı, 1-7.

33. Basaeed, E., Bhaskar, H., Al-Mualla, M., 2016. Supervised Remote Sensing Image Segmentation Using Boosted Convolutional Neural Networks. *Knowledge-Based Systems*, 19–27.
34. Shao, Y., Lunetta, R., 2012. Comparison Of Support Vector Machine, neural network, and CART Algorithms For The Land-Cover Classification Using Limited Training Data Points. *ISPRS Journal of Photogrammetry and Remote Sensing*, 78-87.
35. Sharma, A., Liu, X., Yang, X., Shi, D., 2017. A patch-Based Convolutional Neural Network For Remote Sensing Image Classification. ***Neural Networks***, 19–28.
36. Singh, A., Singh, K., 2017. Satellite Image Classification Using Genetic Algorithm Trained Radial Basis Function Neural Network, Application To The Detection of Flooded Areas. ***J. Vis. Commun. Image***, 173–182.
37. Szuster, B., Chen, Q., Borger, M., 2011. A Comparison Of Classification Techniques To Support Land Cover And Land Use Analysis In Tropical Coastal Zones. ***Applied Geography***, 525-532.
38. Melgani, F., Bruzzone, L., 2004. Classification of Hyperspectral Remote Sensing Images With Support Vector Machines. ***IEEE Transactions On Geoscience And Remote Sensing***, 1778-1790.
39. Kavzoglu, T., Colkesen, I., 2009. A kernel Functions Analysis For Support Vector Machines For Land Cover Classification. ***International Journal of Applied Earth Observation and Geoinformation***, 352–359.
40. Otukei, J., Blaschke, T., 2010. Land Cover Change Assessment Using Decision Trees, Support Vector Machines And Maximum Likelihood Classification Algorithms. ***International Journal of Applied Earth Observation and Geoinformation***, S27–S31.
41. Maulik, U., Chakraborty, D., 2011. A self-trained Ensemble With Semisupervised SVM: An application To Pixel Classification Of Remote Sensing Imagery. ***Pattern Recognition***, 615–623.

42. Mountrakis, G., Im, J., Ogole, C., 2011. Support Vector Machines In Remote Sensing: A review. **ISPRS Journal of Photogrammetry and Remote Sensing**, 247–259.
43. Maulik, U., Chakraborty, D., 2013. Learning with Transductive SVM for Semisupervised Pixel Classification Of Remote Sensing Imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, 66–78.
44. Liu, Y., Zhang, B., Wang, L., Wang, N., 2013. A self-trained Semisupervised SVM Approach To The Remote Sensing Land Cover Classification. **Computers & Geosciences**, 98-107.
45. Jain, D., Dubey, S., Choubey, R., Sinhal, A., Arjaria, S., Jain, A., Wang, H., 2017. An approach For Hyperspectral Image Classification By Optimizing SVM Using Self Organizing. **Journal of Computational Science**, 1-8.
46. Petropoulos, G., Kalaitzidis, C., Vadrevu, K., 2012. Support Vector Machines And Object-based Classification For Obtaining Land-use/Cover Cartography From Hyperion Hyperspectral Imagery. **Computers & Geosciences**, 99–107.
47. Grinias, I., Panagiotakis, C., Tziritas, G., 2016. MRF-based Segmentation And Unsupervised Classification For Building And Road Detection In Peri-urban Areas Of High-resolution Satellite. **ISPRS Journal of Photogrammetry and Remote Sensing**, 145–166.
48. Su, T., Zhang, S., 2017. Local And Global Evaluation For Remote Sensing Image Segmentation. **ISPRS Journal of Photogrammetry and Remote Sensing**, 256–276.
49. Wang, Qian., Zhang, Q., Zhou, W., 2012. Study on Remote Sensing Image Segmentation Based on ACA FCM. **Physics Procedia**, 1286 – 1291.
50. Kapoor, S., Zeya, I., Singhal, C., Nanda, S., 2017. A Grey Wolf Optimizer Based Automatic Clustering Algorithm for Satellite Image Segmentation. **Procedia Computer Science**, 415–422.
51. Wang, M., Wan, Y., Ye, Z., Lai, X., 2017. Remote sensing image classification based on the optimal support vector machine and modified binary code differential colony optimization algorithm. **Information Sciences**, 50–68.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı soyadı : MOTHANA EBRAHEEM MOHAMMAD AL-KARKHI

Uyruğu : IRAK

Doğum Tarihi ve Yeri :18-06-1979-IRAK-DIYALA

Medeni Durumu :Evli

E-mail : mothanashafta79@yahoo.com

Yazışma Adresi :KAYSERİ-TALAS-KAYSERİ Rezidans-daire 603

EĞİTİM

Derece Kurum Mezuniyet Tarihi

Yüksek Lisans Harita Mühendisliği /ERCIYES Üniversitesi 2019

Lisans Technical college/Baghdad 2003

Lisa AL-Sharif AL-Radhi secondary 1998

İŞ DENEYİMLERİ

YIL	Kurum	Görev
2005	Eğitim Bakanlığı	Mühendis

YABANCI DİL

TÜRKÇE

İNGİLİZCE