



**GÖKTÜRK 2 UYDU VERİLERİNİN ARAZİ ÖRTÜSÜ VE
KULLANIMININ UZAKTAN ALGILAMA VE MAKİNE
ÖĞRENMESİ YÖNTEMLERİ İLE TESPİTİNİN
ARAŞTIRILMASI**

YÜKSEK LİSANS TEZİ

BİNNAZ METİN

**MERSİN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**UZAKTAN ALGILAMA VE COĞRAFİ BİLGİ SİSTEMLERİ
ANABİLİM DALI**

**MERSİN
ARALIK - 2022**

**GÖKTÜRK 2 UYDU VERİLERİNİN ARAZİ ÖRTÜSÜ VE
KULLANIMININ UZAKTAN ALGILAMA VE MAKİNE
ÖĞRENMESİ YÖNTEMLERİ İLE TESPİTİNİN
ARAŞTIRILMASI**

YÜKSEK LİSANS TEZİ

BİNNAZ METİN
ORCID ID: 0000-0002-8240-9680

MERSİN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

UZAKTAN ALGILAMA VE COĞRAFİ BİLGİ SİSTEMLERİ
ANABİLİM DALI

DANIŞMAN
PROF. DR. MURAT YAKAR
ORCID ID: 0000-0002-2664-6251

MERSİN
ARALIK- 2022

ÖZET

GÖKTÜRK 2 UYDU VERİLERİNİN ARAZİ ÖRTÜSÜ VE KULLANIMININ UZAKTAN ALGILAMA VE MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE TESPİTİNİN ARAŞTIRILMASI

İnsan ve çevre arasındaki ilişkiyi daha iyi anlamak, ekosistemdeki değişimlerin farkına varmak ve sürdürülebilir bir planlama hizmeti sunmak bakımından arazi kullanımı ve örtüsü (AK/AÖ) değerlendirmeleri önem taşımaktadır. Gelişen teknolojiyle birlikte uydu görüntüleri AK/AÖ belirlemede yaygın olarak kullanılmaya başlanmıştır. Uyduların farklı mekânsal ve zamansal çözünürlükte görüntüleyebilme kabiliyetleri istenilen verilerin hızlı ve güncel olarak takip edilebilmesi açısından AK/AÖ çalışmalarının önemli bir parçası olmuştur. Aynı zamanda arazi örtülerinin spektral yansıma değerleri ile uydu sensörlerinin çeşitli dalga boylarında veri elde etmesiyle arazi örtüsünün tipi belirlenebilmektedir. Uzaktan algılama yöntemleriyle AK/AÖ doğru ve verimli bir şekilde belirlenmesi iyi görüntü sınıflandırma yöntemleri gerektirir. Bu bağlamda bu tez çalışmasında Türkiye'nin uydusu olan Göktürk-2 uydusu ile ücretsiz erişilebilen Landsat-8, Sentinel-2 uydularının AK/AÖ sınıflandırmasında performansları araştırılmıştır. Arazi sınıfları ekili tarım, ekilmemiş tarım, kentsel, çorak ve sulak alan olarak belirlenmiştir. Sınıflandırma işlemi için literatürde sıklıkla kullanılan makine öğrenimi algoritmalarından destek vektör makineleri (SVM), K- En yakın komşuluk (K-NN), Bayess, Karar ağaçları (DT), Rastgele ağaç (RT) algoritmaları kullanılmıştır. Kullanılacak sınıflar doğrultusunda iki farklı çalışma alanı seçilmiştir ve seçilen sınıflarda sınıflandırma algoritmalarının performansları incelenmiş olup üç farklı uydu kendi içinde karşılaştırılması yapılmıştır. Çalışma alanı 1 için; tez kapsamında SVM algoritmasının Göktürk-2 (%98) ve Sentinel-2 (%96) uydularında diğer algoritmalarla göre daha başarılı sonuç verdiği tespit edilmiştir. Çalışma alanı 2 için genel değerlendirme yapıldığında en etkili sonuç G2 uydu görüntüsünde SVM (%98) algoritması gelirken G2 uydusunda diğer algoritmalar incelendiğinde diğer uydu görüntülerine göre daha iyi performans sağlanmış olup S2 için SVM(%96) sınıflandırılması da oldukça başarılı görülmüştür. Landsat uydusunun her iki çalışma alanında başarısı G2'den daha düşük performans gösterdiği tespit edilmiştir. Seçilen uydular ve kullanılan yöntemler doğrultusunda en başarılı sonucu her iki çalışma alanı içinde Göktürk-2 uydusu SVM algoritmasının göstermiş olduğu tespit edilmiştir.

Anahtar Kelimeler: Arazi Kullanımı- Arazi Örtüsü, Makine Öğrenmesi, Göktürk-2, Sentinel-2, Landsat-8.

Danışman: Prof. Dr. Murat Yakar, Mersin Üniversitesi, Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Anabilim Dalı, Mersin.

ABSTRACT

INVESTIGATION OF LAND COVER AND LAND USE OF GÖKTÜRK 2 SATELLITE DATA BY REMOTE SENSING AND MACHINE LEARNING METHODS

Land use and cover (LU/LC) assessments are important in terms of better understanding the relationship between humans and the environment, recognizing changes in the ecosystem, and providing a sustainable planning service. With the developing technology, satellite images have started to be widely used in determining LU/LC. The ability of satellites to display in different spatial and temporal resolutions has been an important part of LU/LC studies in order to monitor the desired data quickly and up to date. At the same time, the type of land cover can be determined by the spectral reflection values of the land covers and the satellite sensors obtaining data at various wavelengths. Accurate and efficient determination of LU/LC by remote sensing methods requires good image classification methods. In this context, in this thesis, the performances of the Göktürk-2 satellite, which is the satellite of Turkey, and the Landsat-8 and Sentinel-2 satellites, which can be accessed free of charge, in LU/LC classification were investigated. Land classes were determined as cultivated agriculture, uncultivated agriculture, urban, barren wetland. For the classification process, support vector machines (SVM), K-Nearest neighbor (K-NN), Bayess, Decision trees (DT), Random tree (RT) algorithms, which are frequently used in the literature, were used. Two different study areas were selected in line with the classes to be used, and the performances of the classification algorithms in the selected classes were examined and compared within their satellites. For study area 1; Within the scope of the thesis, it was determined that the SVM algorithm gave more successful results in Göktürk-2 (98%) and Sentinel-2 (96%) satellites compared to other algorithms. When the general evaluation is made for study area 2, the most effective result is the SVM (98%) algorithm in the G2 satellite image, while when the other algorithms are examined in the G2 satellite, better performance has been achieved compared to the other satellite images and the SVM (96%) classification for S2 has been found to be quite successful. It has been determined that the Landsat satellite has a lower performance than G2 in both study areas. It has been determined that the Göktürk-2 satellite SVM algorithm has shown the most successful result in both study areas in line with the selected satellites and the methods used.

Keywords: Land Use – Land Cover, Machine Learning, Göktürk-2, Sentinel-2, Landsat-8

Advisor: Prof.Dr. Murat Yakar, Department of Remote Sensing and Geographic Information Systems, Mersin University, Mersin.

TEŞEKKÜR

Tez çalışması ve yüksek lisans eğitimim boyunca ilgi ve desteğini esirgemeyen, gelecekteki mesleki hayatımda da bana verdiği değerli bilgilerden faydalanacağımı düşündüğüm danışman hocam sayın Prof. Dr. Murat Yakar'a teşekkürü borç biliyor ve şükranlarımı sunuyorum.

Tezimin tüm aşamalarında yanımda olan, bilgi ve tecrübelerini esirgemeyen ve hayatım boyunca asla pes etmemem gerektiğini öğreten Arş. Gör. Abdurrahman Yasin Yiğit'e; yüksek lisans sürecinde ders ve akademik çalışmaları beraber yürüttüğümüz aynı zamanda tezimin son aşamasına kadar hoşgörüsünü ve desteğini esirgemeyen, gelecekteki hayatında çok daha başarılı olacağına inandığım kıymetli Yük. Müh. Seda Nur Gamze Hamal'a sonsuz teşekkürlerimi sunarım. Ek olarak tez çalışmam için Göktürk-2 Uydu görüntülerinin temini için Türkiye Cumhuriyeti Milli Savunma Bakanlığı Hava Kuvvetleri Komutanlığı'na, Fotogrametri laboratuvarındaki donanımları kullanmama olanak tanıyan Mersin Üniversitesi Harita Mühendisliği Bölümüne teşekkür ederim.

Yaşamım boyunca desteklerini esirgemeyen ve daima arkamda duran annem Döndü Sarı, babam Cemal Sarı ile değerli ağabeylerim Cemil Sarı, Abdullah Sarı, Hüseyin Sarı'ya; her an destek olan ve bana güç veren eşim Harita Müh. Emre Metin'e teşekkür ederim.



İÇİNDEKİLER

	Sayfa
İÇ KAPAK	i
ONAY	ii
ETİK BEYAN	iii
ÖZET	iv
ABSTRACT	v
TEŞEKKÜR	vi
İÇİNDEKİLER	vii
TABLolar DİZİNİ	viii
ŞEKİLLER DİZİNİ	ix
SİMGELER VE KISALTMALAR	x
1. GİRİŞ	1
1.1. Amaç ve Kapsam	2
1.2. Hipotez	2
2. KAYNAK ARAŞTIRMALARI	3
2.1. Literatür Taraması	3
2.2. Uzaktan Algılamada Arazi kullanımı ve Arazi Örtüsü	7
3. MATERYAL VE YÖNTEM	13
3.1. Göktürk-2 Uydusu ve Özellikleri	13
3.2. Landsat-8 OLI uydu görüntüsü	15
3.3. Sentinel-2 uydu görüntüsü	16
3.4. Nesne Tabanlı Sınıflandırma Yöntemi	17
3.4.1. Eğitim Nesnelerinin Belirlenmesi	20
3.5. Makine Öğrenmesi Algoritmaları	21
3.5.1. Destek vektör makinesi (SVM)	21
3.5.2. K-En Yakın Komşu Yöntemi (K-Nearest Neighbor/K-NN),	22
3.5.3. Bayess	23
3.5.4. Karar ağacı öğrenmesi (Decision Tree/DT)	24
3.5.5. Rastgele Ağaç (Random Tree/RT)	24
3.6. Doğruluk analizi	25
4. BULGULAR VE TARTIŞMA	29
4.1. Çalışma Alanları ve Uydu görüntüsü	29
4.2. Veri Ön işleme	31
4.3. Sınıflandırma	32
4.4. Doğruluk Analizi Değerlendirmesi	41
5. SONUÇLAR VE ÖNERİLER	45
KAYNAKLAR	46
ÖZGEÇMİŞ	61

TABLolar DİZİNİ

	Sayfa
Tablo 3.1. Göktürk-2 uydusunun teknik özellikleri.	14
Tablo 3.2. Görüntü İşleme Seviyeleri.	14
Tablo 3.3. Göktürk 2 uydusunun kamera parametreleri.	15
Tablo 3.4. Landsat-8 uydusunun teknik özellikleri.	16
Tablo 3.5. Sentinel-2 uydusunun teknik özellikleri.	17
Tablo 4.1. Çalışmada kullanılan veriler ve özellikleri.	30
Tablo 4.2. Her iki çalışma alanı için eğitim ve toplam segment sayısı.	34
Tablo 4.3. Çalışma alanı 1 için TTA maskesine dayalı doğruluk analizi.	41
Tablo 4.4. Çalışma alanı 2 için TTA maskesine dayalı doğruluk analizi.	42
Tablo 4.5. Çalışma alanı 1 için makine öğrenme algoritmalarının doğruluk analizi.	43
Tablo 4.6. Çalışma alanı 2 için makine öğrenme algoritmalarının doğruluk analizi.	44

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 3.1. Göktürk-2 Uydusu.	13
Şekil 3.2. Landsat 8 Uydusu.	15
Şekil 3.3. Sentinel 2 Uydusu.	17
Şekil 3.4. SVM algoritmasının genel gösterimi.	22
Şekil 3.5. K-NN algoritmasının genel gösterimi.	23
Şekil 4.1. Çalışma alanı.	29
Şekil 4.2. (a) Göktürk-2 (b) Sentinel-2 (c) Landsat-8 Çalışma Alanı 1.	30
Şekil 4.3. (a) Göktürk-2 (b) Sentinel-2 (c) Landsat-8 Çalışma Alanı 2.	31
Şekil 4.4. Göktürk2, Ölçek parametresi araştırılması.	33
Şekil 4.5. Çalışma alanı 1 için sınıflandırılmış AK/AÖ görüntüsü.	37
Şekil 4.6. Çalışma alanı 2 için sınıflandırılmış AK/AÖ görüntüsü.	40

SİMGELER VE KISALTMALAR

Kısaltma/Simge	Tanım
AK	Arazi Kullanımı
AÖ	Arazi Örtüsü
AÖ/AK	Arazi Örtüsü/Arazi Kullanımı
SVM	Destek Vektör Makineleri
K-NN	K-En Yakın Komşu
DT	Karar Ağaçları
RT	Rastgele Orman
CBS	Coğrafi Bilgi Sistemleri
UA	Uzaktan Algılama
G2	Göktürk-2
S2	Sentinel-2
L8	Landsat-8
OLI	Operational Land Imager
TIRS	Thermal Infrared Sensor
SAR	Sentetik Açıklı Radar

1. GİRİŞ

Yeryüzünde geniş ölçekli çalışmalarda arazi kullanımının belirlenmesi, çevresel değişikliklerin incelenmesi, mevcut doğal kaynakların korunması ve envanterlerinin çıkarılması gibi birçok çalışma için Arazi Kullanım (AK) planlarına ve Arazi Örtüsüne (AÖ) ihtiyaç duyulmaktadır. Arazi kullanımı arazinin hizmet ettiği amaca göre yerleşim alanı, yaban hayatı ortamı veya tarım gibi örneklendirilebilir. Arazinin mevcut özelliği, hangi kullanım alanını içerdiği ve zamanla değişen arazi kullanım değişimlerinin tanınması, arazi kullanımı konuları içinde yer almaktadır (Sertel ve Akay, 2015). Arazi Örtüsü ise, dünya üzerindeki kara parçasını ve üzerinde yetişmekte olan ormanlık alanlar, çalılıklar, tarım alanlar ve otsu bitkiler gibi canlı popülasyonları, sulak alanları, yerleşim yerleri, binaları ve yollar gibi insan eliyle de oluşturulmuş doğal ve beşerî unsurları kapsamaktadır (Çölkesen, 2009). Arazi Örtüsü/Arazi Kullanımı (AÖ/AK); bitki örtüsü endeksi, biyokütle ve karbon içeriği gibi bir dizi biyofiziksel değişken elde etmek için yaygın olarak kullanılmaktadır. Daha da önemlisi, AÖ/AK modeli ve değişimi, temeldeki doğal ve/veya sosyal süreçleri yansıtarak Dünya üzerindeki birçok farklı alanın modellenmesi ve anlaşılması için gerekli bilgileri sağlar. Arazi Örtüsü/Arazi Kullanımı ve değişimi hakkında bilgi, doğal kaynakların etkili planlanması ve yönetimi için de kritik öneme sahiptir.

Gelişen teknolojiyle birlikte uzun zamandır Uzaktan Algılama (UA) teknolojileri AÖ ve AK belirleme çalışmalarında yaygın olarak kullanılmaktadır (Liu vd., 2006; Rokade vd., 2007; Hu vd., 2010; Kunwar vd., 2010). Uyduların farklı mekânsal ve zamansal çözünürlükte görüntüleyebilme kabiliyetleri istenilen verilerin hızlı ve güncel olarak takip edilebilmesi açısından AK/AÖ çalışmalarında önem arz etmektedir (Gómez-Chova vd., 2015; Hütt vd., 2016). Nüfus artışıyla birlikte değişen kentsel ve kırsal alanların haritalanması ve alan yayılımının izlenmesi, zamansal ve mekânsal değişimin incelenmesi gibi çalışmalarda elde edilen uydu görüntülerinin işlenmesi ve daha anlamlı sonuçlar elde edilmesi üzerine bilimsel araştırmalar ve uygulamalar yapılmaktadır. Aynı zamanda AK/AÖ spektral yansıma değerleri ile uydu sensörlerinin çeşitli dalga boylarında veri elde edilmesi AK/AÖ tipini belirlenebilmesine olanak sağlamaktadır (Sönmez ve Sarı, 2016). AK/AÖ uygulamalarında kullanılan uydu görüntülerinin mekânsal çözünürlüğü sınıflandırma sonrası elde edilen haritalarda detay seviyesini ve haritaların coğrafi bilgilerinin doğruluğunu etkilemektedir. AK/AÖ uzaktan algılama yoluyla doğru ve verimli bir şekilde haritalandırmak için doğru görüntü sınıflandırma yöntemleri kullanılması gerekmektedir. Ne yazık ki, sınıflandırma algoritmalarının etkinliğini ve doğruluğunu etkileyebilecek çok sayıda faktör (görüntü çözünürlüğü ve atmosferik durum vb.) vardır. Farklı çevre koşulları altında farklı problemler için farklı AK/AÖ sınıflandırma yöntemlerine ihtiyaç duyulabilir, bu da zaman ve mekânda görüntü sınıflandırma sürecinin genelleştirilmesini ve otomasyonunu son derece zorlaştırır. Bununla birlikte görüntülerinin analiz edilmesinde birçok farklı sınıflandırılma yöntemi geliştirilmiş ve kullanılmıştır. Bu çalışmada destek vektör makine (Support Vector machines- SVM) ,K-En yakın komşu (K-Nearest Neighborhood -K-NN), Bayess, karar ağaçlar (Decision trees -DT) , Rastgele Orman (Random TREE - RT) sınıflandırma algoritmalarının performansları incelenmiştir.

1.1. Amaç ve Kapsam

Bu tez çalışmasında arazi kullanımı haritası için Göktürk-2 (G2) uydu görüntüleri kullanmak ve arazi örtüsü sınıflandırılması için literatürde çok az çalışılmış olan G2 uydusunun kullanılabilirliği araştırılmak istenmiştir. Söz konusu uydu görüntülerinin sınıflandırılmasında ileri sınıflandırma algoritmalarından olan SVM, K-NN, Bayess, DT, RT sınıflandırıcılarını kullanmaktır. Sınıflandırma sonuçlarının detaylı bir şekilde analizini ve karşılaştırılmasını yapmaktır. Elde edilen veriler ile yüksek doğrulukta ve kalitede tematik harita üretmek ve uygulanan metotların parametrelerinin de performanslara olan etkileri bu çalışmada araştırmak istenmiştir. Böylelikle Türkiye'nin yerli ve milli uydusu olan G2'nin diğer araştırmacılara altlık oluşturacağı, varılan sonuç neticesinde tespit edilen eksik yanlarının daha sonraki uydu çalışmalarına önemli ölçüde katkı sağlayacağı düşünülmektedir.

1.2. Hipotez

Uzaktan Algılama ile yüksek çözünürlüklü uydu görüntülerinde AK/AÖ haritaları yapılmaktadır. Uyduların farklı konumsal ve zamansal çözünürlükte görüntüleyebilme kabiliyetleri istenilen verilerin hızlı ve güncel olarak takip edilebilmesi açısından AK/AÖ çalışmalarının önem arz etmekte olsa da her uydu görüntüsü ile AK/AÖ yapılabilmesi için çeşitli düzeltmelere ihtiyaç duyulmaktadır. Türkiye için yerli ve milli optik görüntüleme uydusu olan ve aktif görevde olan G2 uydusunun Arazi Örtüsü/Arazi Kullanımı açısından sonuç doğruluğu yeterli olması ekonomi ve sürdürülebilirlik açısından önem arz etmekte olup mevcut makine öğrenmeleri algoritmalarında kullanımı da mümkündür.

2. KAYNAK ARAŞTIRMALARI

Verimli tarım arazileri veya ormanlık alanları; yerleşim yeri veya sanayi faaliyetlerinde kullanılması, tarım alanını plansız kullanımından ormanlık alanlarının tarım arazisine dönüştürülmesi gibi birçok problem mevcuttur. Hızlı nüfus artışından dolayı toprağın gerçek yapısı bozulmakta ya da değişmektedir. Ayrıca mevcut kaynaklar nitekim plansız ve kontrolsüz gerçekleşen durumlardan ötürü kaybedilir. Bununla beraber birçok çevre sorunu ortaya çıkmakta olup AK/AÖ çalışmaları, gelecek nesillere mümkün ölçüde yaşanılabilir bir doğa bırakma açısından büyük bir öneme sahiptir (Turan vd., 2021). Özellikle hızlı nüfus artışı ile beraber sürekli gelişme gösteren kentlerin AK/AÖ çalışmalarının yapılması önem arz etmektedir.

Hızlı bir AK/AÖ analizleri ihtiyacından dolayı yeryüzü hakkında hızlı ve doğru bilgiye ulaşma ihtiyacı artmıştır. Ayrıca AK/AÖ analizinde ortaya çıkan büyük veriler içerisinde ihtiyaca yönelik hedef bilgilerin çıkartılması için de çalışmalar artış göstermiştir. Bu ihtiyaçlar doğrultusunda UA Yöntemleri arazi kullanımı ve arazi örtüsü çalışmalarında kullanılmaya başlanmış olup makine öğrenmesi algoritmalarının tercih edilmesi ile beraber AK/AÖ çalışmalarında önemli gelişmeler yaşanmıştır.

Landsat-8 (L8), Sentinel-2 (S2) gibi uyduların ücretsiz erişime açık olması araştırmacılar için büyük avantaj sağlasa da özellikle AK/AÖ gibi çalışmalarda uydu görüntülerinin çözünürlükleri yapılacak analizler için önemli bir etmen olmaktadır (Altun ve Türker, 2021). Çalışmaların birçoğu ücretsiz erişime imkân vermesinden dolayı L8 ve S2 uydu platformlarına ait görüntüler ile yapılsa da AK/AÖ çalışmalarında çözünürlüğün etkisinden dolayı daha yüksek çözünürlüğe sahip uydu platformları ile de çalışmalar oldukça fazladır. Bu çalışmalar doğrultusunda özellikle AK/AÖ çalışmalarında UA uydu görüntülerinin önemi kanıtlanmıştır (Kaya ve Polat, 2021). Her ne kadar mevcut ücretsiz uydu görüntüleri ile bu çalışmalar yapılsa da birçok ülke kendi uydu platformlarını tercih etmekte olup uydu görüntüleri ile AK/AÖ çalışmalarına önem vermektedir. Bu çalışmaları neticesinde UA alanındaki eksiklikler tespit edilip sonraki uydu platformları çalışmalarına katkı sağlanmak istenmektedir. Bu amaç doğrultusunda literatür incelendiğinde Türkiye'nin kendi uydusu olan G2 ile arazi örtüsü ve arazi kullanım çalışmalarında çok sıklıkla kullanılmamaktadır. Bu bölümde ise, G2 uydusu ile yapılan çalışmalar ve arazi kullanımı/arazi örtüsü çalışmalarında uzaktan algılama ile ilgili literatür araştırmaları incelenmiş ve sunulan çözüm önerileri belirtilmiştir.

2.1. Literatür Taraması

Arazi Kullanımı/Arazi Örtüsü ile literatürde birçok çalışma yer almaktadır. Bunlardan bazıları bitki örtüsü, toprak, yerleşim alanları verim tahmini, tarım alanların ve ürünlerin belirlenmesi, ormanlık alanlar, kentsel alanların belirlenmesi gibi birçok çalışmayı kapsamaktadır. Tez kapsamında çalışılacak

olan G2 uydu görüntüleriyle yapılan çalışmalar incelenmiş olup, literatürde Landsat, Sentinel gibi uydulara nazaran daha az çalışılmıştır.

Literatür incelendiğinde Mutluoğlu ve Güven (2017) G2 bilimsel çalışmalara katkı sağlamış olup daha çok geometrik doğruluğu üzerinde analizler yapmışlardır. Çalışmalarında 30 yer kontrol noktası ve 61 bağımsız kontrol noktası kullanarak Konya test alanı üzerinde 4 piksel planimetrik ve 3,5 piksel yükseklik doğruluğunu incelemiş olup ayrıca 481 referans yükseklik noktası kullanarak sonuç sayısal yüzey modelinin doğruluğunu değerlendirmişlerdir. Çalışma alanı için ortalama yükseklik hatası 9,3 m bulmuşlar ve bu sonuçların georeferanslama hatasına karşılık geldiğini belirtmişlerdir.

Teke (2016), çalışmasında RASAT ve G2 uydularının görüntülerini işlemek için otomatik bir iş akışı tanımlamıştır. Çalışmada otomatik uydu görüntü işleme, radyometrik kalibrasyon, MTF keskinleştirme, bant kaydı, parlama düzeltme, coğrafi referanslama, ortorektifikasyon, pansharpening, renk geliştirme ve kenar keskinleştirmeyi incelemiş olup eksikliklerden bahsederek gelecek çalışmalara tavsiyelerde bulunmuştur.

Göktürk-2 stereo görüntülerinin kalitesi ve analizi çalışmalarında ise Atak vd. (2015), 90 m çözünürlük ile dijital yüzey modelini üretmiştir. Görüntüler, 11 yer kontrol noktası ve 60 bağımsız kontrol noktası kullanılarak yönlendirmişlerdir. Yüzey modeli, karşılık gelen SRTM1 sürüm 2 verileriyle karşılaştırılmıştır. Karşılaştırma, ortalama 10.51 m hata ve 56.45 m standart sapma ile sonuçlanmıştır.

Kalkan vd. (2015) uydu görüntü verilerinin görünür ve NIR bantlarında görüntüleyebilme kabiliyeti vejetasyon ayırımında önemli olduğundan bahsetmişler ve G2 görüntülerinin bitki örtüsünü ayırt etme performansını test ederek sonuçları L8 görüntüleri ile karşılaştırmışlardır. Sonuç olarak NDWI değerlerinin karşılaştırılması sonucunda aynı mekânsal çözünürlük için yakın sonuçlar elde edilmiştir.

Sakarya vd. (2016) ise G2'nin İç Anadolu Bölgesi'nde Tuz Gölü üzerinde ilk yer temelli mutlak radyometrik kalibrasyon yaklaşımını gerçekleştirmişlerdir.

Bayram vd. (2017), çalışmalarında L8 ve G2 uydu görüntüleriyle kıyı şeridi çıkartma çalışmasında G2 için eğitim sayısının artırılması gerektiği sonucuna ulaşmış olup nesne tabanlı sınıflandırmanın piksel tabanlı sınıflandırmaya göre daha başarılı sonuçlar elde ettiğinden bahsetmişlerdir.

Gürçan vd. (2016), G2 uydusu tarafından çekilen görüntülerdeki her bir pikseli “toprak”, “yeşil alanlar”, “yaş ya da su ihtiva eden bölgeler” veya “diğerleri” sınıfları olarak kategorize etmişlerdir. Çalışmada Ayırma Analizi için Kısmi En Küçük Kareler ” yöntemi kullanılmıştır. Bu yöntem en çok benzerlik algoritmasına göre daha iyi sonuçlar vermiş olup çalışma sonucunda kalıcı bir matematiksel model geliştirilmiştir.

Topan vd. (2016), Toplam 72 yer kontrol noktası ile stereo G2 görüntüleri kullanarak Zonguldak Test alanı üzerinden 3 piksellik coğrafi referans doğruluğu sağlamışlardır. Çoban (2016), çalışmasında ormancılık uygulamalarında, Türkiye'nin yerli uyduları olan rasat ve G2 uydularının teknik özelliklerini

ve diğer uydularla karşılaştırmasını yapmıştır. Göktürk 2 uydusu için pankromatik ve multispektral bantların mekânsal çözünürlüklerinin orman kadastro dışında pek çok çalışmada kullanılabileceği sonucuna varmıştır.

Bağdatlı vd. (2016) , G2 uydu görüntüsü ile Nevşehir ili Sarıhıdır mevkiinde arpa kabak-yonca, bağ-nadas tarım ürünlerinin sınıflandırılması yapmışlardır. Sınıflandırmada kullanılan yöntemler; en çok benzerlik, destek vektör makineleri yöntemleri olup destek vektör makineleri yönteminin daha başarılı sonuç verdiğini aktarmışlardır. Teke ve Yardımcı (2016) çalışmalarında, Harran Ovası'nda buğday, mısır ve pamuk ürünlerinde aynı yıl içinde farklı günlere ve aylara ait olacak şekilde seçilen G2görüntülerine Spectral Angle Mapper ve Dynamic Time Warping yöntemlerini uygulayarak %99'un üzerinde sınıflandırma doğruluğu elde etmişlerdir. Günlü ve Gögerçin (2017), ormanlık alanda G2 uydu görüntüsü ile meşrecenin hacmi göğüs yüzeyi, sayısı, orta çap ve boyunun tahmin edilmesini incelemişlerdir ve çoklu regrasyon analizi ile bu sınıflar arasındaki ilişkiyi açıklamışlardır. Göktürk-2 uydu görüntüsüne ait dört bantın parlaklık değerleri (bant 1, bant 2, bant 3 ve bant 4) ile bu bantların kullanımıyla elde edilen vejetasyon indislerinin değerlerini hesaplamışlardır. Çalışma sonucunda vejetasyon indis değerleri kullanılarak elde edilen modeller, bant parlaklık değerleri ile elde edilen modellere göre daha iyi sonuçlar verdiği görülmüştür. Kocaman vd. (2017), çalışmalarında 2015 ve 2017 yıllarına ait iki farklı G2 veri seti kullanarak Bergama Test alanı üzerinden görüntü radyometrik kalitesi, oryantasyonu ve Sayısal Yüzey Modeli oluşturma doğruluğunu araştırmışlardır.

Kaynarca ve Demir (2018), yapmış oldukları çalışmada G2 ile binaların tespit edilebileceği ancak sundurma gibi yapıların da bina olarak algılandığı için sar verisiyle hibrit olarak çalışması gerektiğini ve SAR verisindeki C bandı sinyallerini yansıtmadığı için kentsel yapıların tespitinde de daha doğru sonuçlar üretildiğini aktarmışlardır. Çalışmada Sar görüntüleme için Sentinel 1A verisi kullanılmış olup optik görüntüleme için G2 verisi kullanılmıştır. Sarp vd. (2018), AK/AÖ sınıflarının belirlenmesi amacıyla kentsel alanların çıkartılması ana temalı çalışmalarında, Gram-Schmidt yöntemi kullanarak 2,5 metreye keskinleştirilmiş MSS bantlardan Spektral Açık Haritalama ve DVM yöntemi kullanılarak sınıflandırma yapmışlardır. Destek Vektör Makinelerinin çalışma alanına ait arazi kullanım sınıflarının belirlenmesinde Spektral Açık Haritalama yöntemine göre daha iyi bir sınıflandırma yöntemi olduğunu aktarmışlardır. Yeşilyurt ve Ertürk (2018), otomatik yol çıkarımı çalışmasında patika açma ve kısıtlı patika açma tekniği olmak üzere iki farklı yaklaşım kullanmışlardır. Çalışma sonunda kısıtlı patika açma tabanlı yöntem G2 verilerinden otomatik bir yol çıkarımı yaklaşımı için tatmin edici bulunmuştur. Batur ve Maktav (2018), L8 Oli ve Sentinel 2A görüntülerinin yüksek spektral çözünürlüğünü kullanıp G2 görüntülerinin ise yüksek mekânsal çözünürlüğünü kullanarak hem yüksek mekânsal hem de spektral çözünürlüğe sahip daha güvenilir görüntüler sağlamışlardır. Çalışmada çoklu regrasyon analizi, yapay sinir ağları, destek vektör makineleri ve temel bileşenler analizleriyle su kalitesini incelemişlerdir. Gazel vd. (2018), çalışmalarında Moorea Adası üzerinde alınan G2 stereo ve Pleiades 1A üçlü görüntüleri görüntü kalitesi, yöneltme ve konum belirleme doğruluğu, sayısal yüzey oluşturma, pan-keskinleştirme, ortofoto oluşturma ve sınıflandırma açılarından karşılaştırmalı olarak incelemişlerdir.

Görüntüler arasında çekim açıları, görüntü sayısı, yersel çözünürlük, radyometrik çözünürlük, bulutluluk oranı, yöneltme modeli ve kamera kalibrasyonu açısından önemli farklar bulunduğu bahsetmişlerdir. Çalışmada G2 görüntü yöneltmesi için polinomlarla iz modellemesi yapılmış ancak yazılımın esnekliğinin sınırlı olması nedeniyle parametrelere yeterince müdahale edilemediğini söylemişlerdir. Kontrol noktalarının sayısı artırılarak ve G2 için özelleştirilmiş bir görüntü yöneltme ve self-kalibrasyon algoritması kullanılarak daha yüksek konumsal doğruluk elde edilebileceğini aktarmışlar ancak G2'nin pek çok uygulama için yeterli doğrulukta sayısal yükseklik modeli üretiminde ve nesne çıkarımında kullanılabileceğini öngörmüşlerdir. Akar ve Tunç (2019) yapmış olduğu çalışmada Hyperion EO1 spektral çözünürlüğü ile G2 uydu verisinin multispektral ve pankromatik görüntülerine 8 farklı yöntem ile görüntü kaynaştırma yapmıştır. Elde edilen görüntülerden RT ve DVM algoritmalarıyla kırsal ve kentsel alanda bitki ve su indisleri çıkartarak rastgele orman yönteminin SVM göre daha başarılı olduğunu bulmuştur. Ardından Akar ve Tunç (2019), Hyperion EO1 hiperspektral uydu görüntüsünün, yüksek spektral çözünürlüğünden yararlanılarak G2 ile görüntü bütünleştirme yapılarak arazi örtüsü ve kullanımı çalışmasını yapmışlardır.

Özcan ve Aytaş (2019), G2 uydu görüntüleri ile jipsli toprakların zaman içinde ki değişimlerini gözlemlemek için 2014 yılına ait uydu görüntülerinden tarım, yerleşim, mera, çayır-otlak ve dolin gölleri tanımlanarak sınıflandırma işlemi yapmışlardır. Çalışma sonundaki doğruluk analizine göre sınıflandırma başarısı %88 ve Kappa değeri 0.92 bulunmuştur. Abujayyab vd. (2020), obje çıkarımı çalışmalarında gemilerin tespiti için G2 uydusunun kullanılabilirliğini araştırmak istemişlerdir. Çalışma sonucunda Derin Konvolüsyon Sinir ağları modeli önerilmiştir. Sonuç olarak G2 ile gemiler ve diğer cisimler arasında ayırım yapılabilir sonucuna ulaşılmıştır. Kuruca vd. (2021) G2 ile yapılan çalışmada orman yangını alanının belirlenebilmesi için Landsat ve worldwide-2 uydu görüntüsüyle karşılaştırmalar yapmışlardır. Yapılan çalışmada kullanılan SVM ve RT algoritmaları kullanılmıştır. Doğruluk analizine göre SVM sınıflandırması G2 ve L8 görüntüleri için benzer kappa istatistikleri ve genel doğruluk verirken, Worldview-2 performansı daha yüksek genel doğruluk göstermiştir. Landsat-8 görüntüleri için iki sınıflandırma yöntemi arasında anlamlı bir fark olmamasına rağmen, hem G2 hem de Worldview-2 için SVM'nin RT algoritmasına göre daha iyi performans göstermiştir. Sonuç olarak G2 yangın alanlarının haritalanmasında kullanılabileceği belirlenmiştir.

Arazi örtüsü ve arazi kullanımına dair araştırmalar yapıldığında literatürde L8 ile S2 uydu görüntülerinin özellikle kullanıcılara açık olmasından dolayı (Gómez vd., 2016) çok sayıda çalışma mevcuttur. Landsat-8, S2 ve G2 uydu görüntülerine ait çalışmalar analiz edilerek; Landsat uydu görüntüsüyle bitki örtüsü (Genç vd., 2010; Pekkan vd., 2020; Li vd., 2014; Wu vd., 2015; Skakun vd., 2018; Huang vd., 2015; Zhang vd., 2019; Bostancı ve Genç, 2007) toprak (Silvero vd., 2021; Sutariya vd., 2021; Mohammadpoor ve Eshghizadeh, 2021; Nguyen vd., 2020; Mohamed vd., 2020; De Castro Padilha vd., 2020; Milewski vd., 2020; Yang vd., 2020), yerleşim alanları (Lemus-Canovas vd., 2020; Yang vd., 2020; Pu vd., 2020; Bala vd., 2020; Mathan ve Krishnaveni, 2020; Mishra ve Pant, 2020) verim tahmini (Ouyang vd., 2017; Liao vd., 2019; Nuarsa vd., 2012; Aghighi vd., 2018; Skakun vd.,

2017; Khan vd., 2020; Chen ve Jing, 2017; Bai vd., 2019) tarım alanların ve ürünlerin belirlenmesi (Ahmadian vd., 2016; Semmens vd., 2016; Fieuzal vd., 2020; Skakun vd., 2019; Madugundu vd., 2018; Wang vd., 2015; Liu vd., 2015) ormanlık alanlar (Richter vd., 2021; Charrua vd., 2021; Morgan vd., 2021; Armanto vd., 2021; Thomas vd., 2021; Xu vd., 2021) gibi çok fazla çalışmada tercih edilmiştir. Ayrıca ile L8 arazi örtüsü ve arazi kullanımı (Jia vd., 2014; Karakizi vd., 2018; Zhou vd., 2018; Forkuor vd., 2018; Ed Chaves vd., 2020; Sánchez-Espinosa ve Schröder, 2019; De Mattos Scaramuzza vd., 2017; Sekertekin vd., 2017; Alhawiti ve Mitsova, 2016; Zaitunah vd., 2018; Kumar vd., 2021; Rakhmonov vd., 2021; Wu vd., 2021) üzerine birçok çalışma mevcuttur.

Sentinel-2 ile bitki örtüsü (Demirpolat ve Laloğlu, 2018; Apaydın ve Abdikan, 2021; Kaya ve Polat, 2019; Gao vd., 2021; Hill, 2013), orman (Göksel vd., 2016; Lin vd., 2014) yerleşim alanı (Huang vd., 2015; Zhang vd., 2019; Mohamed vd., 2020; De Castro Padilha vd., 2020; Milewski vd., 2020) verim tahmini, tarım alanlar ve tarımsal ürün tespitinde (Dizdaroğlu, 2019; Murthy vd., 2003; Sonobe vd., 2017; Belgiu vd., 2018; Kaya ve Polat, 2019) toprak (Demirpolat ve Leloğlu, 2018), arazi örtüsü kullanımı (Kaya vd., 2020; İrfanoğlu ve Balçık, 2018; Thanh noi ve Kappas, 2018; Qiu vd., 2019; Weigand vd., 2020; Stroman vd., 2020; Sofu vd., 2020; Kuc ve Chormański, 2019; Bostancı ve Genç, 2007; Than Noi ve Kappas, 2018; Abdi, 2020) gibi birçok çalışma mevcuttur.

Yukarıda da belirtildiği gibi Landsat ve Sentinel uydu görüntülerinin arazi örtüsü kullanımı ve diğer alanlarda sıklıkla tercih edilmiştir fakat G2 ile arazi örtüsü kullanım çalışmalarında çok sık tercih edilmediği sonucuna varılarak bu tez çalışmasında G2 uydu görüntüleri ile AK/AÖ çalışması yapılmasına karar verilmiştir.

2.2. Uzaktan Algılamada Arazi kullanımı ve Arazi Örtüsü

Nesne ile herhangi bir temas bulunmaksızın nesne hakkında bilgilerin toplanması ve bilgilerden anlamlı bir yorum çıkarılması işlemlerinin tümüne uzaktan algılama adı verilmektedir (Longley vd. 2005; Jensen, 2009). Uzaktan Algılama çalışmalarının genel çalışma prensibinde nesne üzerine çarpan ışıkların (doğal veya yapay) geri yansımalarıyla algılayıcıların tüm bu geri yansıtımları kaydedip dijital veri haline dönüştürülmesi işlemi olarak tanımlanır (García-Mora vd., 2012). Uzaktan algılama teknolojisi meteoroloji, çevrebilim, arkeoloji, jeoloji, peyzaj mimarlığı, şehir bölge planlama, coğrafya, harita mühendisliği gibi birçok disiplinlerde kullanılmaktadır (Richards, 1999; Barrett, 2013).

Arazi Kullanımı ve arazi örtüsü hakkında ki bazı bilgiler, uzaktan algılama teknolojisinin ortaya çıkmasından daha öncesine dayanmaktadır (Campbell, 1983). Daha geniş ölçekli arazi kullanım ve arazi örtüsü haritalarının üretiminde uydu görüntülerinin ortaya çıkması bu çalışmalara teşvikte bulunmuştur. Havadan görüntüleme yapmadan önce, AK/AÖ haritalarının üretimindeki temel yöntem yersel yöntemler olup yer etüdü yapmaktı. Yer etütleri geniş alanları kapsayan çalışmalarda sistematik olarak haritalanması zaman ve zahmet açısından zor bir süreç olmuştur (Fuller vd., 1994; Crone, 2000) Uzaktan algılama kavramı hayatımıza girmeden önce 1973'te Fransız topoğraf araştırmaları, 1807 de Napolyon

kadastrası ve 1762’de Avusturya’nın kadastral çalışmaları ve araştırmaları topografik ve kadastral haritalar içermektedir (Rochel vd., 2017). 1931 ile 1938 yılları arasında yürütülen ‘Land Utilization Survey of Great Britain’ çalışması gibi AK/AÖ bilgilerinin haritasını çıkarmak için araştırmaların örnekleri vardır (Campbell, 1983). Bununla birlikte, genel kural, arazi kullanım bilgilerinin daha genel amaçlı (örneğin, topografik, kadastral haritalar) veya çok tematik bir yaklaşımla (örneğin, tarımsal kullanımlar ve üretim) diğer haritaların bir parçası olarak sunulmasıydı.

Teknolojik gelişmelerle birlikte 1957’de 1 uydunun fırlatılmasıyla AK/AÖ haritalanması çalışmalarında dönüm noktası olmuştur (Emery ve Camps, 2017). Uydular yeryüzünden görüntüler almaya başladığında, yeryüzü hakkında geniş ölçekli alanlarda kısa sürede bilgiler elde edilmeye başlanmıştır (Chuvieco, 2016). Uyduların elektromanyetik spektrumlar sayesinde yüzeyden yansıyan ışınları geri kaydederek, her arazi örtüsü için farklı yansıtım eğrisi karakterize edilebilmekte ve tanımlanmaktadır. Böylelikle haritacılıkta, arazi örtülerini otomatik olarak belirlemek için gerekli olan bilgilerin teminini sağlamaktadır.

Elde edilen görüntülerin yansımalarından, belirsizlik ve hatalara yol açabilecek çeşitli önemli sorunlara sahiptir. Bir arazi örtüsü, bitki yoğunluğu ve fenolojideki farklılıklar nedeniyle birkaç farklı spektral tepki sunabilir. Farklı arazi örtüleri de benzer bir spektral tepki sunabilir. Spektral karışıklık olarak bilinen bu sorun, çeşitli ve karmaşık manzaralarda kritiktir ve çok sayıda sınıflandırma hatasına yol açabilir.

Uzaktan algılama teknolojisinde yukarıda belirtilen sorunlara çözüm olarak ham görüntüde bazı düzeltme işlemleri yapılmaktadır. Kısaca ham olarak elde edilen uydu görüntülerinde birtakım hatalar ya da eksiklikler vardır. Bunlar sistematik ya da sistematik olmayan hatalar olabilirler ve uygulamada kullanılabilmesi için bazı düzeltmeler yapılması gerekir. Bu düzeltmelere ön işlem denir. Ön işlemler görüntüden istenilen verinin çıkartılması ve analizinden önce yapılır. Temel amaç; algılayıcıdan ve platformdan kaynaklanan radyometrik ve geometrik bozulmaları düzeltmektir. Sırasıyla radyometrik düzeltme, atmosferik düzeltme, geometrik düzeltme ve görüntü kaynaştırma gibi teknikleri içermektedir.

Radyometrik düzeltme; Sensörden ve çevresel etkilere kaynaklanan hataların giderilmesidir. Bu hatalara örnek olarak; algılayıcının bantları arasında ki algılama farklılığı, kayıp veya hatalı tarama, piksel değerlerinin ortalamasının hatalı piksele atanması ve atmosferik gürültüler verilebilir. Bu hatalar düzeltilmelerinin bazıları yer istasyonunda yapılır fakat bazen kullanıcıların tekrardan radyometrik düzeltme yapmasına ihtiyaç duyulur.

Atmosferik düzeltme; Algılayıcılar görüntülenene alana ait elektromanyetik radyasyon yoğunluğunu kaydeder. Bu şekilde her bant için ayrı parlaklık değeri elde edilir. Algılayıcının özelliğine ve radyometrik çözünürlüğüne bağlı olarak parlaklık değerleri farklılık göstermektedir. Landsat MSS 0-63 aralığında parlaklık değeriyle tanımlarken, TM algılayıcısı 0-255 aralığında ölçmektedir (Liu vd., 2006). Parlaklık değeri olarak kaydedilen enerji spektral imzaları yansıtmaz. Parlaklık değerleri algılayıcılara özeldir. Görüntünün çekildiği anda açısına, güneşin konumuna ve hava koşullarına

bağlıdır. Çalışmalarda parlaklık değeri yerine spektral yansıma değerleri kullanılması birçok çalışma için önemlidir. İki görüntü karşılaştırmasında spektral değerlerin kullanılması daha avantajlıdır. Spektrometre ölçümleri sayesinde direk olarak yeryüzünden nesnelerin yansıma değerleri kaydedilir. Böylelikle spektral kütüphaneler oluşturulur (Mather ve Koch, 2011). Yeryüzüne gelen ışın atmosferden geçer ve hedeften tekrar atmosferden geçerek algılayıcıya ulaşır. Gelen enerjinin bir kısmı soğurulur bir kısımda saçılarak tekrar algılayıcıya döner ve kayıt edilir. Anlamalı yansıma ölçümleri için görüntü de atmosferik etkiler düzeltilmelidir.

Geometrik düzeltme; Uydu görüntülerinin belirli bir harita projeksiyonuna dönüştürülmesi için yapılmaktadır. Ham halde elde edilen uydu görüntüsü, arazi koordinat sistemine dönüştürülür. Bu işlem uygun sayıda ve homojen olarak dağılmış yer kontrol noktaları yardımıyla yapılmaktadır. Bu işleme görüntüden haritalandırma işlemine geçiş denilmektedir. Farklı bir yöntem olarak görüntüden görüntüye dönüşüm işlemi örnek verilmektedir. Daha öncesinde georeferanslandırılmış görüntü ile her iki görüntüdeki ortak noktalar tespit edilerek bu noktalar ile geometrik düzeltme işlemi yapılır. Fakat geometrik düzeltme sonucunda piksellere ait sayısal bilgiler değişebilir. Geometrik düzeltme yapılmış görüntülerin yeni piksellerin sayısal değerlerinin belirlenmesi yeniden örnekleme denir. Düzeltme öncesi ham görüntünün piksel sayısı yardımıyla yeni piksellerin değeri belirlenir. Yeniden örnekleme yöntemleri;

- En yakın komşuluk
- Bilineer enterpolasyon
- Kübik eğri olarak; üç farklı metot vardır.

Görüntü kaynaştırma; Uydu görüntülerinde çok bantlı uydu görüntüleri ile aynı alanın yüksek mekânsal çözünürlüğe sahip pankromatik görüntülerle zenginleştirilmesine görüntü kaynaştırma denir. Kaynaştırma işlemi ki amaç pankromatik görüntüdeki mekânsal çözünürlüğün multispektral görüntüyle birleştirilmesidir. Ayrıca spektral içeriğin gerçeğe uygun olarak kaydedilmesidir. Kaynaştırma işlemi ile görüntünün görsel analizi kolaylaşmaktadır.

Uydu teknolojisindeki gelişmelerle birlikte yukarıda belirtilen düzeltmeler sayesinde görüntülerin daha anlamlı ve daha doğru sonuçlar vermesi sağlanmıştır. Bu gelişmeler beraberinde uydu uzaktan algılama teknolojisinin AK/AÖ çalışmalarında kullanılabilirliğini artırmıştır. Arazi kullanımı ve arazi örtüsü haritalandırılması daha kolay, daha ucuz ve daha hızlı hale geldikçe, birçok kurum, bilim adamı ve diğer kullanıcılar, farklı ölçeklerde AK/AÖ veri kümeleri üretmeye başlamışlardır. (Grekousis vd., 2015; Loveland, 2016). İlk çabalar ağırlıklı olarak bölgesel ve ulusal ölçeklere odaklanmıştır (Loveland, 2016). Ancak, kaba çözünürlüklerde tüm Dünya'yı kapsayan ücretsiz görüntüler sağlayan sensörlere sahip ilk uyduların ortaya çıkması, ilk küresel AK/AÖ veri kümelerinin geliştirilmesine olanak sağlamıştır (Congalton vd., 2014; Mora vd., 2014; Grekousis vd., 2015).

Arazi kullanımı ve Arazi örtüsü haritalandırma çalışmalarında farklı uydu görüntülerinin kullanılmasının birçok sebebi olmakla birlikte, en önemli nedenleri arasında veriye ulaşım ve elde edilen

görüntünün çözünürlüğüdür. Uzaktan algılamada dört farklı çözünürlük kavramı olmakla beraber, bunlar mekânsal, spektral, radyometrik ve zamansal çözünürlük olarak adlandırılmaktadır.

Mekânsal çözünürlük; literatürde, geometrik çözünürlük, konumsal ve alansal çözünürlük gibi değişik biçimde isimlendirilmiştir. Algılayıcı tarafından kaydedilen alanın yeryüzünde kapladığı alan olarak ifade edilmektedir. Mekânsal çözünürlük algılayıcının anlık görüş (IFOV) açısıyla da ilişkilidir. Kaydedilen alan görüntüde bir piksel olup mekânsal çözünürlük elde edilen görüntüde ki piksel boyutuyla ilişkilidir. Çözünürlüğün yüksek olması, görüntüde ki nesneleri birbirinden ayırt etme ve daha iyi yorumlanmasını sağlar. Konumsal çözünürlük Düşük ($>100m$), orta ($10m-100m$), yüksek ($<10m$) olmak üzere üç farklı sınıfta kategorilendirilmektedir.

Spektral çözünürlük; algılayıcının kaydedeceği dalga boyu (bant sayısı ve genişliği) ilişkilidir. Spektral özellik ise yeryüzünün ve de cisimlerin yansıma, geçirme ve soğurma özelliğidir. Algılayıcılar bu özellikleri kayıt eder. Bant genişlikleri algılayıcının spektral ayırma gücünü ifade etmedir. Ayrıca bantlar elektromanyetik spektrumun farklı bölümlerine karşı duyarlıdır. Spektral çözünürlük yüksek ise dalga boyu aralığı küçüktür. Kısaca; elektromanyetik spektrumun çok ve küçük parçalara ayrılmasıyla spektral ayırma gücü arasında doğru orantı vardır.

- Yüksek Spektral çözünürlük(>220 bant)
- Orta Spektral çözünürlük (3-15 bant)
- Düşük spektral çözünürlük(<3 bant)

Radyometrik çözünürlük; uydu görüntülerinin elektromanyetik enerji miktarına duyarlılığını gösterir. Piksel yapısı görüntünün yapısıyla ilişkiyken radyometrik özellikler görüntüdeki gerçek bilgiyi tanımlamaktadır. Enerji görüntüdeki renk tonu sayısıdır. Radyometrik çözünürlük renk tonlarının ve derecelerinin ayırt edilebilme kabiliyetidir. Derece ve tonlandırma ne kadar fazla olursa, ayırt etme gücünde artar. Radyometrik çözünürlük ikili sayı sistemi ya da bit cinsinden, 2^n formülü ile tanımlanır. Örneğin 1 bit veri 21 eşitliğinden siyah ve beyaz olarak ifade edilir.

Zamansal çözünürlük; uydunun belirli bir alandan ardışık olarak görüntü alma sıklığıdır. Zamansal çözünürlükte görüntünün hangi açıyla alındığı önemlidir. Uydunun yörüngesi değiştirilerek görüntü alınamaz ama yönelim (açı) değiştirilerek görüntü alınabilir. Literatürde yalpalama açısıyla aynı bölgenin görüntülerinin alınması zamansal çözünürlük olarak kabul edilmiştir. Örneğin nadirden alınan bir görüntü ile tekrardan nadirden alınan görüntü için 30 gün gerekli olabilmektedir. Fakat yalpalama açısıyla aynı yerin görüntüsünü 2-3 gün olmaktadır. Bir bölgede farklı zamanlarda alınan görüntüler yeryüzündeki değişimlerle ilgili çalışmalarda kullanılabilir. Değişik zamanlarda görüntü almak çok zamanlı görüntü elde edilmesine olanak sağlar.

Uzaktan algılanmış görüntülerden yeryüzüne ait bilgilerin çıkarılması için birçok istatistiksel analizler ve yorumlama teknikleri kullanılmıştır. Sınıflandırmanın amacı; doğal ve yapay objelere ait spektral bilgileri istenilen şekilde sınıflara atamaktır. Objelerin farklı spektral yansıma değerleri ile ham görüntüdeki piksellerin veya görüntü objesinin arazi örtüsü sınıflarından birisine otomatik bir şekilde

kategorize edilmesidir (Lillesand vd., 2007). Bu sayede uydu görüntüsünden elde edilen veriler istenilen sınıftaki bilgiye dönüştürülür.

Sınıflandırma işlemi kullanıcılar için iki aşamadan meydana gelmektedir.

- Çalışılan bölgenin arazi örtüsünü ortaya çıkaracak sayıda ve kategoride olası sınıfların belirlenmesi

- Piksellerin spektral özellikleriyle; sınıflandırma ve karar kuralı şeklinde tanımlanan karar verme yöntemi şeklinde, piksellerin sınıf etiketlerinin tahmin edilmesi

Sınıflandırma sonuçlarının kalitesini etkileyen faktörler;

- Uygun sınıflandırma yaklaşımı
- Sınıflandırıcının eğitimi için örnek piksellerin tespiti
- Görüntü ön işleme
- Özellik çıkarımı
- Uygun sınıflandırma algoritması seçimi
- Çalışma alanın ölçeği
- Kullanıcının tecrübesi gibi birçok etken sıralanabilir.

Sınıflandırma işlemi genel olarak ikiye ayrılır. Kontrollü (denetimli, eğitilmiş) ve Kontrolsüz (denetimsiz, eğitimsiz) sınıflandırma şeklinde iki yaklaşım mevcuttur.

Kontrolsüz Sınıflandırma; görüntü üzerindeki piksellerin kullanıcı müdahalesi olmadan bazı algoritmalar yardımıyla otomatik olarak gruplandırılması ya da kümelendirilmesidir. Çalışma alanına ait yeterli veri olmaması ve genel bilgiye ihtiyaç olduğu zamanlarda kullanılmaktadır. Görüntüde ki piksellere ait farklı bantlarda ki değerler kullanılarak, benzer piksellerin otomatik olarak aynı sınıfa atama işlemidir. Bu işlem sonucunda spektral sınıflar oluşur. Spektral sınıfların gerçekte hangi sınıfa ait olduğunu kullanıcı belirlemektedir.

Karar kuralı olarak minimum uzaklık ilkesi benimsenir. Pikseller görüntünün sol üst köşesinden sağa doğru satır satır analiz edilmesiyle oluşur. Oluşacak piksel ile her bir küme ortalaması arasında spektral uzaklık hesaplanır, en yakın kümeye atanır.

Kontrollü sınıflandırma da görüntünün hangi sınıflara ayrılacağı bellidir. Kontrollü sınıflandırmada ilk adım oluşturulacak sınıflara ait örneklem alanları tespitidir. Örneklem aşamasında kullanıcı farklı arazi örtüsü çeşitlerini temsil edecek örnek alanlarını seçer. Örneklem alanlarının spektral özelliklerini açıklayacak sayısal değerler oluşturur. Bir sonra ki adımda sınıflandırma yapılır. Sınıflandırma adımı; uydu görüntüsünde ki pikseller en çok benzerlik gösterdikleri arazi örtüsüne dâhil edilir. Fakat görüntü elemanı örneklem bölgeleriyle uyumumuzsa bilinmeyen olarak tanımlanır. Bilinmeyen görüntü elemanları daha sonrasında uygun arazi örtüsü sınıfına tanımlanır.

Kısaca sınıflandırma işleminde uygun sınıflandırma algoritması seçilir. Böylelikle model oluşturulur. Model tüm uydu görüntüsüne uygulanarak algoritmalar yardımıyla her pikselin ait olduğu sınıflar hesaplanır. Sınıflandırma sonucunda tematik haritalar üretilir.

Kontrollü sınıflandırma teknikleri en genel anlamda piksel tabanlı ve obje tabanlı olarak iki temel grupta incelenmektedir. Piksel tabanlılar uygulama türüne ve yardımcı verilere göre; alt piksel tabanlı ve alan tabanlı gibi sınıflandırma teknikleri geliştirilmiştir.

Bu çalışmada obje tabanlı kontrollü sınıflandırma yöntemi kullanılacaktır.

Piksel tabanlı sınıflandırma; her pikselin arazi örtüsü sınıfını temsil ettiği kabul edilip bu sınıfa karşılık gelecek şekilde sınıflandırılmasıdır. Piksel tabanlı sınıflandırma tekniğinde, piksellere ait yansıma değerlerinden elde edilen spektral değerler veya bu değerlerde üretilen değişkenler sınıflandırma işlemi için veri serinin oluşturulmasında etkilidir (Çölkesen, 2015) .

Birçok AK/AÖ çalışmasında kullanılan uydu görüntüleri heterojen bir yapıya ve benzer spektral özelliklere sahip karmaşık arazi örtüsü tiplerine sahiptir. Bu nedenle söz konusu görüntülerdeki piksellerin normal bir spektral dağılıma sahip olduğu varsayımı yanlıştır. Öte yandan, mekânsal çözünürlüğü düşük veya karışık piksellere sahip görüntülerde yeterli sayıda eğitim alanı belirlemek zordur. Sınıflandırma sonucunda oluşturulan haritalarının doğruluğunu etkileyen önemli bir faktör de oluşturulan eğitim materyalinin boyutudur. Sınıflandırıcılar, verileri bölmek veya bir alanı sınıflara ayırmak için farklı yöntemler kullandığından, belirli bir sınıflandırma problemini çözmek için kullanılan eğitim veri setinin boyutu, sınıflandırma doğruluğunu etkileyebilir (Foody vd. 2006; Chi ve Feng, 2008).

Obje (nesne) tabanlı sınıflandırma işleminde bir görüntüdeki benzer spektral özelliklere sahip pikselleri gruplayarak bu pikselleri temsil edecek görüntü nesneleri oluşturmaya ve pikseller yerine bu nesneleri sınıflandırmaya dayanır. Bu açıdan bakıldığında nesne tanımlama ve sınıflandırma sürecinde en önemli olan görüntünün pikselleri değil, piksellerin birleşiminden oluşan görüntü nesneleridir. Bu, görüntüdeki milyonlarca piksel yerine, oluşturduğunuz nesneleri etiketleyecektir (Çölkesen, 2015).

Segmentasyon işlemi çoğunlukla büyük nesneleri daha küçük parçalara ayırmayı içerir. Nesne tabanlı görüntü sınıflandırması sırasında, benzer spektral özelliklere sahip piksellerin gruplandırılması ve görüntü nesnelerinin oluşturulması, görüntü bölütleme olarak tanımlanır. Bu açıdan parçalanma, küçük parçalara bölme, birleştirme veya yeniden düzenleme olarak da tanımlanabilir (Çölkesen, 2015).

AK/AÖ çalışmaları güncel verilerin işlenmesi, sürdürülebilirlik açısından zamansal ve mekânsal değişimlerin tespitiyle UA alanında büyük ve karmaşık veriye dayalı bir süreçtir. Gelişen teknolojiyle beraber elde edilen yüksek çözünürlükteki uydular AK/AÖ çalışmalarında sıklıkla kullanılmaya başlanmıştır. Verinin büyüklüğü ve karmaşıklığıyla birlikte verinin sınıflandırılması ve modellenme süreçlerini otomatikleştiren veri analizi yöntemi olarak makine öğrenimi literatürde sıklıkla kullanılmıştır. Makine öğrenimi verilerin eğitilebildiği ve sisteme verilerin tanıtılmasıyla, sınıfları tanımlayacağı ve minimum düzeyde kullanıcı müdahalesiyle kararlar alınan bir yapay zekâ dalıdır. Çalışma kapsamında Materyal ve Metot kısmında kullanılan algoritmalar anlatılmıştır

3. MATERYAL VE YÖNTEM

Bu tez çalışmasında Göktürk-2, Landsat 8 ve Sentinel-2 uydu görüntüleri kullanılmıştır. Tez kapsamında iki farklı çalışma alanı seçilmiş olup kullanılan verilerin özellikleri Tablo 4.'de verilmiştir. Göktürk-2 uydu görüntüleri T.C. Milli Savunma Bakanlığı Hava Kuvvetleri Komutanlığından, Landsat ve Sentinel uydu görüntüleri ise Copernicus Open Access Hub sitesinden ücretsiz olarak temin edilmiştir. Elde edilen veriler ArcGIS PRO ve E-Cognition yazılımlarında işlenmiştir. Doğruluk analizinde referans olarak kullanılan veriler Google Earth Pro yazılımı ile belirlenmiştir.

3.1. Göktürk-2 Uydusu ve Özellikleri

Göktürk-2 uydusu 18 Aralık 2012'de Çin fırlatma sahası Jiuquan'dan fırlatılmıştır. 686 kilometre uzaklıktaki yörüngeye 12 dakika sonra yerleştirilmiştir. İlk sinyal 19:39'da Norveç'in Tromsø kentinden alınmıştır. Göktürk-2 uydusu TÜBİTAK, UZAY ve TAI ile geliştirilmiş olup araştırma geliştirme uydusu olup aynı zamanda elektro-optik yer gözlem uydusudur. Çalışma prensibi elektromanyetik ışınları elektrik sinyallerine çevirmesidir. Tek veya çok kanallı sistemlerden oluşurlar ve yalnızca görünür ışıktaki değil, aynı zamanda kızılötesi ve termal kızılötesi radyasyonda da çalışırlar (Atak vd., 2015).

Göktürk-2 uydusunun 4 bandı vardır ve Yakın kızılötesi bant (Near infrared -NIR) ve stereo görüntüleri alabilir (Atak vd., 2015).



Şekil 3.1. Göktürk-2 Uydusu.

Kaynak: http://www.nik.com.tr/content_sistem_uydu.asp?id=34

Tek parça görüntü 5x20 km boyutunda çekilmekte olup ham görüntünün boyutu yani çerçeve genişliği 20x20 km'dir. Pankromatik bandın kamera üzerinde kırmızı, yeşil ve mavi bantların hepsi ile

yaklaşık 0.1 mm'lik farkı olup yakın kızılötesi (NIR) bant ile de yaklaşık 15 mm'lik bir fark mesafesi olması sonucunda, bantlar konumsal bir fark ile görüntüleme yapmaktadırlar. (Atak vd., 2015).

Tablo 3.1. Göktürk-2 uydusunun teknik özellikleri (Atak vd. 2015).

Yörünge	Güneş Eş Zamanlı Yörünge
Yörünge Yüksekliği	~ 700 km
Dünya Çevresindeki Tur Süresi	~ 98 dakika
Günlük Yer İstasyonu Temas Süresi	~ 40 dakika (gündüz + gece)
Global Gözlem Alanı Kabiliyeti	Bütün Dünya
Tekrar Ziyaret Zamanı	Ortalama 2,5 gün
Depolama Kapasitesi	8 GB + 32 GB
Mekânsal Çözünürlük	Siyah-beyaz: 2.5m, Renkli(RGB):5 m NIR:5 m
Radyometrik Çözünürlük	11 bit
Zamansal Çözünürlük	+/-5° çekim açısı 11 gün +/-30° çekim açısı 2-3 gün
Spektral Çözünürlük	Pan:0.42-0.75µm, Blue: 0.422-0.512µm Red:0.596-0.75µm, Green: 0.5-0.584µm NIR:0.762-0.894µm, SWIR: 0.8-1.7µm
Görev Ömrü	5 yıl
Stereo Görüntüleme	100 km x 20 km

Göktürk-2 uydusunun pankromatik çözünürlüğü 2.5m, multispektral bant çözünürlüğü 5m olup 20x20 km çerçeve boyutuna sahiptir (Gürgenburan ve Çınar, 2015).

Göktürk-2 uydu görüntüleriyle doğal afetlerin izlenmesi, zamanla değişen yeryüzünün incelenmesi, istihbarat - keşif çalışmaları ve ayrıca birçok haritacılık ve şehir planlama çalışmaları için uydu görüntüsü ihtiyacının karşılanması amacıyla tasarlanmış ve üretilmiştir (Küpcü,2015).

Tablo 3.2. Görüntü İşleme Seviyeleri(Atak vd. 2015).

Gör. İşleme Seviyesi	Elde edilecek görüntü türleri
Seviye 0 (L0)	Sıkıştırma ve radyometrik çözümleme yapılmış görüntü
Seviye 1 (L1)	Radyometrik düzeltilmiş görüntü
Seviye 2 (L2)	Geometrik olarak düzeltilmiş görüntü
Seviye 3 (L3)	Ortorektifiye edilmiş görüntü
Seviye 4 (L4)	Sayısal Yükseklik Modeli (SYM)
Seviye 5 (L5)	Mozaik görüntü
Seviye 6 (L6)	Tematik Harita(Sınıflandırma/ Analizi)

Tablo 3.3. Göktürk 2 uydusunun kamera parametreleri (Küpcü, 2015)

Kanallar	PAN	Kırmızı	Yeşil	Mavi	NIR
Focal Length (mm) Efektif Odak Uzaklığı (mm)	1416,24	1414,06	1413,14	1413,21	1422,07
Principal Point xo (mm)	0.00	0.0066	0.0098	0.0028	-0.5998
Principal Point yo (mm)	904.011	904.270	904.283	905.420	903.618
Piksel Size (mm) Benek Boyutu X&Y (mm)	0,005	0,01	0,01	0,01	0,01
Sensör COLUMNS Algılayıcı sütunları	8192	4096	4096	4096	4096
Yersel Çözünürlük (m)	2,42	4,95	4,95	4,95	4,95
(Along) Track incidence angle (Yıldız Kamerası)	±30°	±30°	±30°	±30°	±30°
Side (across track) incidence angle	0°	0°	0°	0°	0°

3.2. Landsat-8 OLI uydu görüntüsü

Landsat 8 uydusu 11 Şubat 2013'te California, Vandenberg Hava Kuvvetleri Üssü'nden fırlatılmış olup iki Sensörden oluşmaktadır. Bu sensörler OLI (Operational Land Imager) ve TIRS (Thermal Infrared Sensor) adında iki algılayıcı sistemdir.

Elektromanyetik spektrumun kısa dalga kızıl ötesi ve görünür yakın kızılötesi (VNIR, NIR ve SWIR) aralığında OLI sensörü ölçüm yaparken, TIRS sensörü yüzey sıcaklığını ölçerek ısıyı tespit eder. OLI; geçmişte fırlatılan Landsat uydularına ek olarak kıyı/aerosol çalışmaları için özel olarak tasarlanmış ultra mavi bant, sirrus bulutlarının çıkışı için kısa dalga kızıl ötesi bandı ve bir de kalite değerlendirme bandı içerir. OLI, dokuz adet spektral bant (Coastal/Aerosol + VNIR + SWIR + PAN + CIRRUS) ile veri toplamaktadır. Daha önce üretilen Landsat 5 TM ve Landsat 7 ETM sensörlerinde bulunan bantlarla uyumlu olan 7 bant kullanılmıştır. Böylelikle geçmiş yıllardaki yapılan çalışmalarla uyumlu olması sağlanmıştır (Roy vd., 2014).

**Şekil 3.2.** Landsat 8 Uydusu.

Kaynak: <https://www.usgs.gov/landsat-missions/landsat-8>

Tez kapsamında Landsat-8 için 2,3,4,5 bantları kullanılmış olup Tablo 3.4.'te Landsat uydu görüntüsüne ait bazı bilgiler verilmiştir.

Tablo 3.4. Landsat-8 uydusunun teknik özellikleri (Hakan, 2016).

Yörünge	Güneş eş zamanlı, kutuplara yakın yörünge
Yörünge Yüksekliği	~ 705 km
Dünya Çevresindeki Tur Süresi	~ 99 dakika
Global Gözlem Alanı Kabiliyeti	Bütün Dünya
Tekrar Ziyaret Zamanı	Ortalama 16 gün
Mekânsal Çözünürlük	Siyah-beyaz: 30 m, OLI: 30 m TIR:100 m
Radyometrik Çözünürlük	8 bit / TIRS-12 bit
Zamansal Çözünürlük	16 gün
Spektral Çözünürlük	Band 1 - 0.43-0.45 Band 2 - 0.45-0.51 Band 3 - 0.52-0.60 Band 4 - 0.63-0.68 Band 5 - 0.84-0.88 Band 6 - 1.56-1.66 Band 7 - 2.10-2.30 Band 8 - 0.50-0.68 Band 9 - 1.360-1.390 Band 10 - 10.60-11.19 Band 11 - 11.50-12.51
	Coastal Aerosol Blue Green Red Near-Infrared SWIR 1 SWIR 2 Pankromatik Cirrus TIRS 1 TIRS 2
Şerit genişliği	170x183 km

3.3. Sentinel-2 uydu görüntüsü

Avrupa Uzay Ajansı'nın (ESA) Kopernik Programı gereksinimlerini karşılamak üzere geliştirilen Sentinel-2 uydusu, Dünya yüzeyindeki kara ve kıyı suları üzerinde 10m ila 60m arası mekânsal çözünürlüğe sahip bir optik görüntüleme uydusudur. Sentinel-2A uydusu 23 Haziran 2015'te, Sentinel 2B uydusu 7 Mart 2017'de fırlatılmıştır. Sentinel 2A ve Sentinel2B ikiz uydu takımı güneş ile eş zamanlı yörüngede olup, 180 derece fark ile konumlandırılmış iki kutup yörüngesindedir. Uydu; tarımsal alanlardaki çalışmaları, bitki büyümesi, yıllık ürün tahmini, arazi yüzey koşullarındaki değişikliği, acil durum yönetimi, su kalitesi; arazi örtüsünün belirlenmesi gibi birçok uygulama alanında kullanılmaktadır. Uydu 56° güney ve 84° kuzey enlemleri arasında taramalar yapmaktadır. Zamansal çözünürlüğü ekvatorda 10 gün olmasına karşın 2A ve 2B olmak üzere iki adet uydu olduğu için aynı yer görüntülenmesi 5 günde bir olmaktadır.



Şekil 3.3. Sentinel 2 Uydusu.

Kaynak: http://nik.com.tr/content_sistem_uydu.asp?id=102

Tablo 3.5’de Sentinel 2 uydusuna ait bazı özellikler verilmiştir. Tablo3.5’te de görüldüğü üzere on üç farklı banttan oluşmaktadır. Bu bantların mekânsal çözünürlüğü 10m,20m,60m ve çerçeve genişliği 290 kilometredir (Kaya Y. 2020) . Bu çalışmada mekânsal çözünürlüğü 10 m olan bant 2, bant 3, bant 4 ve bant 8 kullanılmıştır.

Tablo 3.5. Sentinel-2 uydusunun teknik özellikleri (Sentinel-2A User Handbook, 2015).

Sentinel-2	Dalga Boyu (µm)	Çözünürlük (m)
Bant 1 Kıyı Aerosolü	0.443	60
Bant 2 Mavi	0.49	10
Bant 3 Yeşil	0.56	10
Bant 4 Kırmızı	0.665	10
Bant 5 Kırmızı Kenar (Red Edge)	0.705	20
Bant 6 Kırmızı Kenar (Red Edge)	0.74	20
Bant 7 Kırmızı Kenar (Red Edge)	0.783	20
Bant 8 Yakın Infrared (NIR)	0.842	10
Bant 8A Kırmızı Kenar (Red Edge)	0.865	20
Bant 9 Su Buharı	0.9451	60
Bant 10 Kısa Dalga Infrared (SWIR)	1.375	60
Bant 11 Kısa Dalga Infrared (SWIR)	1.610	20
Bant 12 Kısa Dalga Infrared (SWIR)	2.190	20

3.4. Nesne Tabanlı Sınıflandırma Yöntemi

Doğru sınıflandırılmış bir AK/AÖ haritasının elde edilmesi, uzaktan algılama alanında büyük önem taşımaktadır. Bu tür doğruluklar, sınıflandırıcı seçimi, eğitim verilerinin kalitesi, verinin heterojenliği, veri seti, referans haritaları vb. gibi çeşitli faktörlerden etkilenir. Bu çalışmada G2,S2,L8 görüntü serisini kullanarak AK/AÖ sınıflandırması üzerindeki etkilerini anlamak için farklı örnekleme yöntemlerini ve SVM, K-NN, Bayess, DT, RT gibi önemli makine öğrenmesi sınıflandırma

algoritmalarının performansı incelenmiştir. Sınıflandırma yöntemi olarak öncelikle nesne (obje) tabanlı sınıflandırma algoritması ile uydu görüntüleri segmentasyon işlemine tabi tutulmuş ardından makine öğrenme algoritmaları ile sınıflara ayrılmıştır.

Nesne tabanlı veya nesne yönelimli sınıflandırma işlemi spektral ve konumsal bilgiyi kullanır. Süreç, piksellerin spektral özelliklerine, şekillerine, dokularına ve çevreleyen piksellerle mekânsal ilişkilerine göre sınıflandırılmasını içerir aynı zamanda geleneksel piksel tabanlı sınıflandırma tekniklerine göre nispeten yakın zamanda geliştirilmiştir (Hofmann ve Jain, 1987). Piksellerdeki spektral bilgilere dayalı olan piksel tabanlı sınıflandırma yöntemi, nesneler veya görüntü nesneleri olarak tanımlanan nesne tabanlı sınıflandırma yöntemi bu nesne kümelerinden gelen bilgilere dayanmaktadır. Görüntü nesneleri veya özellikleri, spektral özelliklere (örneğin renk), boyuta, şekle ve dokuya ve ayrıca pikselleri çevreleyen bir komşuluk ilişkisine bağlı olarak birbirine benzeyen piksel gruplarıdır. Nesne tabanlı sınıflandırma iki adımlı bir süreçtir. İlk önce görüntü bölümlere ayrılır yani farklı nesnelere veya özelliklere bölünür ve ardından her nesnenin sınıflandırma işlemi gerçekleştirilir (Yiğit, 2020).

Nesne tabanlı sınıflandırmanın ilk adımı olan segmentasyon, Nesne tabanlı sınıflandırma yönteminin en önemli aşamasıdır. Segmentasyon bir görüntünün daha sonra nesne olarak tanımlanan homojen ve örtüşmeyen bölgelere bölünmesi işlemi olarak tanımlanabilir. Bölütlemenin amacı, homojen özelliklere sahip nesnelere dayalı bir nesne kümesi oluşturmaktır. Bölütlemenin sonucu, nesne tabanlı sınıflandırmaya katılan bir nesne/piksel grubu biçimidir ve tek bir piksel değildir. Her piksel, bir nesneyi oluştururken aynı spektral değer grubuna sahiptir (Kalkan ve Maktav, 2010). Nesne bölütleme sonuçları, nesne bölütleme boyutunu üretmek için verilen bölütleme değerinin belirlenmesine bağlıdır. Büyük değerlere sahip segmentasyon, büyük nesneler üretecektir ve bunun tersi de geçerlidir. Bu nedenle, segmentasyon değerinin belirlenmesi nesne tabanlı sınıflandırma yönteminin başarısında önemlidir. Her segmentasyon seviyesi farklı miktarlar ve boyutlar üretir. Segmentasyon sürecinde yetersiz ve aşırı segmentasyon varlığından kaçınmak için uygun tanımlamanın görünümüne dayalı olarak segmentasyon değerinin belirlenmesi gerekmektedir. Sonraki adımlarda, daha küçük görüntü nesneleri, bitişik görüntü nesneleri arasındaki heterojenliğin büyümesini tanımlayan seçilen ölçek, renk ve şekil parametrelerine dayalı olarak daha büyük nesnelerle birleştirilmektedir (Yiğit, 2020). Segmentasyon işleminde kullanılan çeşitli parametreler mevcuttur. Ölçek faktörü; nesnelerin veya özelliklerin ölçeği olarak görüntü bölütleme işlemindeki önemli değişkenlerden arasındadır. Ölçek, ayrı bir bölüm veya nesne olması için bir grupta bulunması gereken minimum piksel sayısını ayarlamaktadır (Burnett ve Blaschke, 2003). Bir görüntü uygun görüntü nesnelere bölündükten sonra, görüntü, kullanıcı tarafından ayarlanan özelliklere ve kriterlere dayalı olarak her bir nesneyi bir sınıfa atayarak sınıflandırılır. Bu kriterler iki genel gruba ayrılabilir, her nesneyle ilgili özellikler (yani renk dokusu) ve nesneler arasındaki ilişkiyi tanımlayan özellikler vardır (Bilgiliöğlu, 2015).

Mekânsal, spektral ve doku özelliklerine dayalı olarak multispektral uydu görüntülerinden anlamlı bilgilerin çıkarılması AK/AÖ çalışmaları için önem arz etmektedir. Ayrıca görüntülerden anlamlı bilgilerin çıkarılması, bir alandaki tarım, yerleşik arazi, çalılar ve diğerleri gibi arazi kullanımı

hakkında bilgi elde etmek için gerçekleştirilir. Arazi kullanım tanımlaması, mekânsal, spektral ve dokuya dayalı segmentasyon sonuçlarının kalitesiyle belirlenir. Bu sonuçlar, bir çokgen şekli üretmek için bir nesne tanımlama sınırı oluşturur. Çokgenler, doğrudan görüntüden yorumlanabilen arazi kullanımına göre sınıflandırılır. İyi bir sınıflandırma yapmak için görüntüleri yorumlama yeteneği gereklidir (Yiğit, 2020) . Sınıflandırmanın belirlenmesinde örnek için görüntü yorumlaması yapılır. Daha sonra bu nesneler uygun sınıflara atanır. Çalışmada kullanılan makine öğrenme algoritmaları, özellik uzayındaki en yakın eğitim örneklerine dayalı olarak nesnelerin veya sınıf üyeliklerinin "değerini" tahmin eden bir yöntemdir. Bu durumda görüntü yorumlama sonuçlarının örnek seçiminde eğitim alanına ihtiyaç duyulmaktadır. Arazi kullanım sınıflandırmasının iyi sonuçlar verebilmesi için görüntü yorumlamalarının dikkatli bir şekilde yapılması gerekmektedir. Her sınıfın örnek seçimi, segmentasyon sonuçlarına dayanmaktadır.

Bu çalışmada, Baatz ve Schäpe (2000) tarafından geliştirilen çoklu çözünürlüklü segmentasyon algoritmasını uygulanmıştır. Çalışmada kırmızı, yeşil, mavi ve NIR spektral bantları kullanılarak eCognition Developer 64 yazılımında segmentasyon yöntemi gerçekleştirilmiştir. Görüntüler, anlamlı görüntü genellemesini engelleyebilecek birçok ayrıntıya sahiptir. Bu nedenle, çoklu çözünürlüklü segmentasyon kullanımı, görüntü nesnesi içindeki ortalama değişkenliği en aza indirme yeteneğinden dolayı tercih edilmiştir. Algoritma, rastgele tek bir pikselde başladığı ve ağırlıklı heterojenliğin en düşük olduğu bölgeyi birleştirdiği bölge büyüyen en uygun şekle sokma problemine benzer. Heterojenliğin tartmak için kullanılan parametreler, görüntü nesnelerinin kompaktlığı, şekli ve ölçeğidir. Çoklu çözünürlüklü segmentasyon algoritmasının ayrıntılı bir açıklaması için Baatz ve Schäpe (2000) çalışmaları incelenebilir. Görüntüdeki pikseller, spektral değer, şekil ve kompaktlık gibi farklı içsel parametrelerin yardımıyla nesne görüntüsünün heterojenliğine göre ağırlıklandırılır ve topolojik, hiyerarşik ve dokusal nesne özelliklerini dahil ederek daha fazla analiz yapmak mümkündür (Blaschke vd., 2014). Bu çalışmada kompaktlık ve şekil değerleri 0,5 olarak belirlenmiştir.

Bölütleme sonucunun kalitesini etkileyen bir diğer önemli faktör ölçektir (Blaschke vd., 2014) ve en uygun ölçek parametresini seçmek için kullanılan uygulamalar çoğunlukla deneme yanılma yöntemiyle yapılmaktadır (Demers vd., 2015). Ancak genel kural ölçeğin boyutunun en az çıkarılacak en küçük nesne kadar büyük ve nesneyi ortadan kaldırmayacak kadar küçük (Baatz ve Schäpe, 2000; Blaschke vd., 2014) olmasıdır.

İç homojenliği yüksek olan farklı pikseller, nesne sınıflarına ayrılırken, bitişik nesneler önemli ölçüde farklılık gösterir. Nesnenin homojenliği, nesne içindeki piksel değerinin standart sapmasına göre değerlendirilebilirken heterojenlik, nesnenin spektral heterojenliği, şekil heterojenliği veya doku heterojenliği ile tanımlanabilir. Nesnenin niteliği, segmentasyon ölçeği tarafından tanımlanan heterojenlik eşliğini aştığında, nesnenin büyümesi durur. Optimizasyondan sonra, her nesnenin iç ağırlıklı heterojenliği en aza indirilir. Segmentasyon nesnesinin heterojenliği (H), spektral heterojenliği ve şekil heterojenliğini içerir ve hesaplamalar Eşitlik 3.1 ve 3.2 kullanılarak hesaplanmıştır.

$$H=\omega_{\text{color}}h_{\text{color}}+\omega_{\text{shape}}h_{\text{shape}} \quad (3.1.)$$

$$h=\omega_{\text{compact}}h_{\text{compact}}+\omega_{\text{smooth}}h_{\text{smooth}} \quad (3.2.)$$

Burada ω_{color} spektral ağırlıktır, ω_{shape} şekil ağırlığıdır ve $\omega_{\text{color}} + \omega_{\text{shape}} = 1$ 'dir; h_{shape} , h_{compact} ve pürüzsüzden oluşan şekil heterojenliğidir; ω_{compact} , kompakt ağırlıktır, ω_{smooth} , pürüzsüz ağırlıktır ve $\omega_{\text{compact}} + \omega_{\text{smooth}} = 1$. Aşağıdan yukarıya bir algoritma olarak, çoklu çözünürlüklü segmentasyon, prosedürün başında her bir pikseli ayrı bir nesne olarak ele aldı. Segmentasyon işlendiğinde, iki optimal görüntü nesnesi seçilir ve birleştirilir (Bilgilioğlu, 2015). Eşitlik 3.3'e göre segmentler heterojenlik değişimine göre seçilir ve birleştirilir:

$$h_{\text{diff}}=(s_a+s_b)h_{\text{merge}}-(s_a h_a+s_b h_b) \quad (3.3.)$$

h_a ve h_b iki orijinal nesnenin heterojenliği, s_a ve s_b orijinal nesnenin boyutu ve h_{merge} birleştirilmiş nesnenin heterojenliğidir. Heterojenliğin değişimini makul bir aralıkta sınırlayarak, büyük varyansa sahip nesneler birleştirilmez. Bu nedenle, birleştirilmiş nesneler heterojenliği önemli ölçüde değiştirmemelidir. Heterojenlik değişimi, segmentasyon ölçekleriyle ilgilidir ve iyi birleştirme sonuçları elde etmek için heterojenliğin değişimi ölçek parametresinden daha büyük olmamalıdır.

3.4.1. Eğitim Nesnelerinin Belirlenmesi

Segmentasyon işleminden sonra sınıflandırma işlemleri için eğitim nesneleri belirlenmelidir. Eğitim nesnelerin sayısı sınıflandırmanın kalitesini etkilemektedir. Bu yüzden eğitim nesnelerinin hangi sınıftan ne kadar olacağına istatistiksel olarak karar verilmelidir (Yiğit, 2020). Bunun için ilk olarak eğitim nesnelerinin sayısı her çalışma alanı için ayrı örneklem belirlenmiştir. Bunun için ilk olarak örneklem alınmasında örneklemin alındığı sınıfı temsil etmesi önemlidir. Bu durumda ne kadar, hangi büyüklükteki bir örneklemin belirlenen sınıfları temsil edebileceği sorunu ortaya çıkmaktadır. Seçilen örneklemin veri kümesini temsil yeterliği bulunmadığında örnekleme hatası olur. Örneklem büyüklüğünü saptamak için veri kümesinin büyüklüğü yani çalışma alanı (38496.80 km²) on binin üzerinde olmasından dolayı bu çalışmada örneklem belirlemek için denklem 3.4 kullanılmıştır

$$n=\frac{Nt^2pq}{d^2(N-1)+t^2pq} \quad (3.4.)$$

N: Toplam segment sayısı (ana kütle sayısı)

n: Sınıfa ait eğitim nesnelerinin sayısı

p: İncelenen olayın görülüş sıklığı (gerçekleşme olasılığı) (0,5)

q: İncelenen olayın görülmeysi sıklığı (gerçekleşmeme olasılığı) (1-p)

t: Belirli bir anlamlılık düzeyinde, t tablosuna göre bulunan teorik değeri (1,96)

d: Olayın görülüş sıklığına göre kabul edilen $\pm$ örnekleme hatası ($\pm 0,05$)

Yukarıdaki denklemde örneklem büyüklüğü için çalışma alanlarının boyutu (38496.80 km²) ile oluşan segment sayısı kullanılarak eğitim nesneleri belirlenmiştir.

Örneklem sayısı belirlendikten sonra: Çalışma alanı 1 için, ekili tarım, ekili olmayan tarım, kentsel alan, çorak; çalışma alanı 2 için ise, ekili tarım, ekili olmayan tarım, kentsel alan, sulak alan olmak üzere sınıflara uygun eğitim nesneleri seçilmiştir (Tablo 4.2) .

3.5. Makine Öğrenmesi Algoritmaları

Sınıflandırma işlemi için her iki çalışma alanı için uydu görüntüleri segmentasyona tabi tutulmuş ardından eğitim nesneleri belirlenerek en makine öğrenme algoritmalarının AK/AÖ çalışmalarında performansları test edilmiştir.


Başlıca makine öğrenimi stratejilerinden biri, bir sistemi daha önce hiç kullanılmamış örneklerle çalışacak şekilde eğiten denetimli öğrenme senaryosudur. Denetimli görüntü sınıflandırmasında, eğitim örneklerini kullanarak belirli bir sınıfa pikseller veya nesneler atamak için sınıflandırıcıyı eğitmeniz gerekir. Sınıf kategorilerine ait eğitim örnekleri, her sınıf kategorisi için eğitim örnekleri oluşturmanıza ve sınıflandırma modelinizin doğruluğunu geliştirmenize yardımcı olacak örneklerin sayısı ve boyutu hakkında bilgi sağlamanıza olanak tanır. Uydu görüntülerinde belirlenen her arazi örtüsü sınıfı için temsili alanlar veya eğitim örnekleri toplanmalıdır. Bir eğitim örneğinin konum bilgisi (segment) ve ilişkili bir arazi örtüsü sınıfı vardır. Görüntü sınıflandırma algoritması, tüm görüntüdeki arazi örtüsü sınıflarını tanımlamak için bir özellik sınıfı olarak kaydedilen eğitim örneklerini kullanır. Çalışmada eğitim örnekleri manuel olarak seçilmiştir.

3.5.1. Destek vektör makinesi (SVM)

Bir destek vektör makinesi (SVM), sınıflandırma ve regresyon analizi için kullanılan, verileri analiz eden ve uydu görüntülerini farklı sınıflara ayırmak ve sınıflar arasındaki belirsizliği azaltıp sınıflandırmayı en üst düzeye çıkartabilmek için verileri uygun biçimde ayırmak hedefleyen bir öğrenme algoritmasıdır. Standart SVM, bir dizi girdi verisi alır ve verilen her girdi için, olası sınıftan hangisinin üyesi olduğunu tahmin etmektedir. Girdi verilerinin her biri sınıflardan birine ait olarak işaretlenen bir dizi eğitim örneği verildiğinde, bir SVM eğitim algoritması, bir kategoriye veya diğerine yeni örnekler atayan bir model oluşturur. Bir SVM modeli, örneklerin uzayda noktalar olarak temsil edilmesidir ve ayrı kategorilerdeki örneklerin mümkün olduğu kadar geniş net bir boşlukla bölünmesi için

haritalanmıştır. Yeni örnekler daha sonra aynı alana eşlenir ve boşluğun hangi tarafına düştüklerine bağlı olarak bir kategoriye ait olduğu tahmin edilir. Destek Vektör Makineleri, karar sınırlarını tanımlayan karar düzlemleri (optimum hiper düzlem) kavramına dayanır. Bir karar düzlemi, farklı sınıf üyeliklerine sahip bir dizi nesneyi ayırır (Şekil 3.4).

Destek Vektör Makineleri modellerinde kullanılabilecek farklı çekirdekler bulunmaktadır. eCognition'a doğrusal ve radyal temel işlev dâhildir. Radyal temel işlev, SVM de kullanılan çekirdek türlerinin en popüler seçimidir.




Şekil 3.4. SVM algoritmasının genel gösterimi.
Kaynak:(Durmazbilek, 2021)

3.5.2. K-En Yakın Komşu Yöntemi (K-Nearest Neighbor/K-NN),

K-En Yakın Komşu Yöntemi (K-Nearest Neighbor/K-NN), basit ve güçlü yapısından dolayı uzaktan algılama alanında sınıflandırma işleminde sıkça kullanılan bir yöntemdir.

K-NN algoritması özellik uzayındaki en yakın eğitim örneklerine dayalı olarak nesneleri sınıflandırılması esasına dayanan bir yöntemdir. k-NN, bir tür örneğe dayalı öğrenme veya işlevin yalnızca yerel olarak tahmin edildiği ve tüm hesaplamanın sınıflandırmaya kadar ertelendiği tembel öğrenmedir. K-En yakın komşu algoritması, tüm makine öğrenimi algoritmalarının en basitlerinden biridir: bir nesne, komşularının çoğunluk oyu ile sınıflandırılır ve nesne, en yakın k komşusu arasında en yaygın olan sınıfa atanır ve k pozitif bir tamsayıdır, genellikle küçüktür. Örneğin K-NN sınıflandırma kuralında k değerinin beş olduğunu varsayılırsa, uygulamada ki verinin test örneğine en yakın 5 eğitim örneğinin çoğunluk sınıf etiketini atamaktır. Eğer $k = 1$ ise, nesne basitçe en yakın komşusunun sınıfına atanır. Bu, k'nin, sınıflandırılmamış bir nesnenin/pikselin yakınında dikkate alınması gereken örnek sayısı olduğu anlamına gelir. En iyi k seçimi verilere bağlıdır: daha büyük değerler sınıflandırmadaki gürültünün etkisini azaltır, ancak sınıf sınırları daha az belirgindir. Şekil 3.5'te K-NN sınıflandırma algoritmasına ait genel gösterim verilmiştir.



Şekil 3.5. K-NN algoritmasının genel gösterimi.

Kaynak: <https://www.datacamp.com/tutorial/k-nearest-neighbor-classification-scikit-learn>

eCognition yazılımı, algoritma sınıflandırıcı ($k=1$ ile K-NN) veya En Yakın Komşu Sınıflandırmasına dayalı sınıflandırma kavramı kullanılarak uygulanabilen bir sınıflandırıcı olarak uygulanan En Yakın Komşuya sahiptir.

3.5.3. Bayess

Bayess sınıflandırıcısı, Bayess teoreminin (Bayess istatistiklerinden) güçlü bağımsızlık varsayımlarıyla uygulanmasına dayanan basit bir olasılıksal sınıflandırıcıdır.

Basit bir ifadeyle, bir Bayess sınıflandırıcısı, bir sınıfın belirli bir özelliğinin varlığının (veya yokluğunun) başka herhangi bir özelliğinin varlığı (veya yokluğu) ile ilgili olmadığını varsayar. Örneğin, kırmızı, yuvarlak ve yaklaşık 4 inç çapında bir meyve elma olarak kabul edilebilir. Bu özellikler birbirine veya diğer özelliklerin varlığına bağlı olsa bile, bir Bayess sınıflandırıcısı, tüm bu özelliklerin bağımsız olarak bu meyvenin elma olma olasılığına katkıda bulunduğunu düşünür. Saf Bayess sınıflandırıcısının bir avantajı, sınıflandırma için gerekli parametreleri (değişkenlerin ortalamaları ve varyansları) tahmin etmek için yalnızca küçük miktarda eğitim verisi gerektirmesidir. Bağımsız değişkenler varsayıldığından, tüm kovaryans matrisinin değil, yalnızca her sınıf için değişkenlerin varyanslarının belirlenmesi gerekir.

3.5.4. Karar ağacı öğrenmesi (Decision Tree/DT)

Karar ağacı öğrenmesi, verileri homojen alt gruplara bölmek için bir dizi kararın verildiği veri madenciliğinde yaygın olarak kullanılan bir yöntemdir. Karar ağacında modelleme dalları olan bir ağaç görünür ve bu ağaçların düğümleri, bölümleri vardır. Bu düğüm ve bölümlerden karmaşık yapıda görülmektedir. Bu modelde ki amaç; birkaç girdi değişkenine bağlı olarak bir hedef değişkenin değerini tahmin edebilecek model oluşturmaktır. Bir ağaç, öznitelik değeri testine dayalı olarak kaynak kümesini alt kümelerle bölerek öğrenme sağlamaktadır. Öğrenme sürecinde türetilmiş her alt kümede özyinelemeli bölümlenme adı verilerek bu şekilde tekrarlama sağlanır. Özyineleme, bir düğümdeki alt kümenin tamamı hedefteki değişkenle aynı değere sahip olduğunda veya bölme işlemi tahminlere artık değer katmadığında tamamlanır. Ağaç oluşturma algoritmaları aracılığıyla yapılan analizlerin amacı, mantıksal (bölünmüş) koşul belirlemektir.

Karar ağacı öğrenmesinde önemli bir parametre olan düğümlere gereken minimum örnek sayısıdır. Bu parametre de örnek sayısı parametresi tarafından tanımlanır. İstenilen sonucu elde edebilmek için doğru boyuttaki ağacı bulmak biraz deneyim gerektirebilir. Çok az bölmeye sahip bir ağaç, gelişmiş tahmin doğruluğunu kaçırırken, çok fazla bölmeye sahip bir ağaç gereksiz yere karmaşıktır. eCognitions parametresi çapraz doğrulama kıvrımlarını ayarlayarak karmaşık yapıda olan modelin az bölmeli mi yoksa çok bölmeli olmasından doğacak karışıklıkla mücadele etmesi için çapraz doğrulama işlemi yapmaktadır. Çapraz doğrulama için, sınıflandırma ağacı öğrenme örneğinden hesaplayarak tahmini doğruluğu test örnekleriyle test etmektedir. Test örneğinin değeri, öğrenme örneğinin değerini aşarsa, bu, çapraz doğrulamanın zayıf olduğunu ve farklı boyuttaki bir ağacın çapraz doğrulamayı daha iyi yapabileceğini gösterir.

3.5.5. Rastgele Ağaç (Random Tree/RT)

Rastgele ağaç (Random Tree/RT) sınıflandırıcısı, belirli bir modelden çok karmaşık bir varlık veya sürecin varsayımsal yaklaşımıdır. Bir girdi vektörü kullanır ve bu girdi vektörünü ormandaki her ağaçla sınıflandırır. Sonlandığı uç düğümünde eğitim örneğinin bir sınıf etiketi ile sonuçlanır. Sonlanma sınıf atama işlemi "oyların" çoğunluğunu alan etiketin atandığı anlamına gelir. Bunu tüm ağaçlar üzerinde yinelemek, rastgele orman tahminiyle sonuçlanır. Tüm ağaçlar aynı girdi özelliklerine sahip farklı veri setleri ile eğitilmiştir.

Tüm ağaçlar, orijinal eğitim setinden oluşturulan farklı eğitim setlerinde aynı özelliklerle eğitilir. Bu, yeniden örnekleme işlemine göre yapılır; her eğitim seti için, orijinal setteki ($=N$) ile aynı sayıda vektör seçilir. Vektörler, bazı vektörlerin bir kereden fazla görüneceği ve bazılarının bulunmayacağı anlamına gelen bir yer değiştirme ile seçilir. Her düğümde, en iyi ayrımı bulmak için tüm değişkenler kullanılmaz, ancak bunların rastgele seçilen bir alt kümesi kullanılır. Her düğüm için, boyutunun tüm düğümler ve tüm ağaçlar için sabitlendiği yeni bir alt küme oluşturulur.

Her düğüm değişkenlerin sayısına göre ayarlanmış bir eğitim parametresidir. Karar ağaçlarından farklı olarak oluşturulan ağaçların hiçbirisi budanmaz. Eğitim süresince rastgele ağaçlardaki hatalar içsel olarak tahmin edilir. Mevcut ağaçlar için eğitim seti değiştirmeli örnekleme yoluyla çizildiğinde bazı vektörler dışarıda kalır. Dışarıda kalan veriye ‘out-of-bag data’ denilmekte olup kısaca ‘oob’ verisi olarak adlandırılmaktadır. Out of Bag Data’nın yaklaşık boyutu $N/3$ olup sınıflandırma hatası oob verilerine dayanarak tahminde bulunur.

3.6. Doğruluk analizi

Tematik (AK/AÖ) haritaların doğruluk değerlendirmesi, uzaktan algılanan AK/AÖ haritalarının güvenilirliği onların doğruluğuna bağlı olduğundan önemlidir. Sınıflandırmadan sonra, sınıfların gerçek uzay ile uyumluluğunu belirlemek için bir doğruluk analizi yapılmalıdır. Doğruluk analizi, sınıflandırmanın doğruluğunu ve güvenilirliğini ölçmek için son adımdır. Bu tez kapsamında, doğruluk analizi için iki yöntem belirlenmiştir. İlk olarak sınıflandırmanın yapıldığı eCognition Developer yazılımında TTA (Test and Training Area) maskesine dayalı bir hata matrisi kullanarak sınıflandırılmış veriler için bir doğruluk değerlendirmesi gerçekleştirilmiştir. Seçilen test alanlarının referans değerleri ile sınıflandırma sonucu karşılaştırılarak bir karışıklık hata matrisi üretilmiş ve sınıflandırma kalitesi test edilmiştir. Doğruluk analizi için bir hata matrisi geliştirilmiş, genel doğruluk, kullanıcı doğruluğu, üretici doğruluğu ve kappa katsayısı analiz edilmiştir.

Genel doğruluk, doğru olarak sınıflandırılan toplam piksel veya görüntü nesnesi sayısının referans verilerindeki toplam öge sayısına bölünmesiyle hesaplanır. Eşitlik 3.5’e göre genel doğruluk,

$$\text{Genel Doğruluk} = \frac{\sum_{k=1}^n N_{k,k}}{\sum_{j=1}^n (\sum_{i=1}^n N_{i,j})} \quad (3.5.)$$

şeklinde olur.

Her bir kategorinin doğruluğu, bu kategoride doğru sınıflandırılmış nesnelerin sayısının karşılık gelen satır veya sütundaki eleman sayısından herhangi birine bölünmesiyle hesaplanır.

Üretici doğruluğu, her kategoride doğru sınıflandırılmış piksel veya nesne sayısının, o kategori için seçilen toplam gerçek örnekleme türü sayısına (sütun toplamı) bölünmesiyle hesaplanır (Eşitlik 3.6).

$$\text{Üretici Doğruluğu} = \frac{N_{i,i}}{\sum_{j=1}^n N_{i,j}} \quad (3.6.)$$

Üretici doğruluğu denklem 4.2’de gösteriliği gibi hesaplanır. Burada, Üretici Doğruluğu, i . kategorinin üretici doğruluğu, n sınıflandırma kategori sayısını oluşturmaktadır. Üretici doğruluğu, görüntüdeki gerçek örtü tipinin ilgili sınıfa dâhil edilme başarısını gösterir.

Kullanıcı doğruluğu, her kategoride doğru olarak sınıflandırılan piksel veya nesne sayısının, o kategoride sınıflandırılan toplam piksel veya nesnelerin (toplam satır) sayısına bölünmesiyle elde edilir. Bu doğruluk kriteri, ekleme hatasının bir ölçüsüdür ve belirli bir kategoride sınıflandırılan piksel veya nesnenin, gerçek dünya toprak örtüsü tipindeki kategoriye temsil etme olasılığını ifade eder. Kullanıcı doğruluğu Eşitlik 3.7'ye göre,

$$\text{Kullanıcı Doğruluğu} = \frac{N_{j,j}}{\sum_{j=1}^n N_{j,i}} \quad (3.7.)$$

Bu prosedürlerin sadece bu alanlardan türetilen istatistiklerin bu alanları kategorize etmek için ne kadar iyi kullanılabileceğini ifade ettiği bilinmelidir. Sonuçlar iyi ise, eğitim alanlarının homojenliğinden, spektral ayrılabilirliklerinden ve uygulanmakta olan sınıflandırma stratejisinden daha fazlası anlamına gelmez.

Doğruluk analizi, sınıflandırma sonucunda elde edilen verilerin referans olarak kabul edilmiş olan veriler ile istatistiksel olarak karşılaştırılmasını esas alan bir doğruluk kontrol etme yöntemidir. Yapılan bu istatistiksel analizler sonucunda elde edilen hata matrisi ile sınıflandırma sonucunun sağlıklı olup olmadığı anlaşılmaktadır. Hata matrisi, 0 ile 1 arasında değişiklik gösteren kappa katsayısı ile istatistiksel olarak analiz edilir (Çölkesen vd., 2007).

Eşitlik 3.8'de k değeri kappa katsayısını göstermek üzere,

$$k = \frac{P_0 - p_h}{1 - p_h} \quad (3.8.)$$

ile hesaplanır. P_0 değeri hata matrisinin köşegenlerindeki elemanların toplamının, her satır veya sütundaki elemanlarının toplamına oranlanması ile elde edilir (Eşitlik 3.9).

$$p_h = \sum p_{\alpha}(i)(p)(i) \quad (3.9.)$$

P_{α} değeri, ayrı ayrı her bir sütunun toplamının, tüm sütunların toplamına bölünmesi ile bulunmaktadır.

P değeri ise, ayrı ayrı her bir satırın toplamının, tüm satırların toplamına bölünmesi ile bulunmaktadır (Musaoğlu 1999).

Ayrıca tez çalışmasında sınıflandırma sonrası doğruluk değerlendirmesi için rastgele örneklenmiş noktalar oluşturularak referans verileriyle karşılaştırmalı analiz yapılmıştır. Bu amaç doğrultusunda referans verisinde noktalar belirlenmiş ve referans noktaları daha sonra aynı konumlardaki sınıflandırma sonuçlarıyla karşılaştırılmıştır. Bu noktaların konumlarının doğruluğunu

test etmek için CBS yazılımında rastgele noktalar atanmıştır. Rastgele atanacak nokta sayısını belirlemek için oluşturulan parçalara göre örneklem ve örneklem uzayına göre nokta sayısı belirlenmiştir. Sınıflandırma sonuçlarının doğrulanması için, sınıflandırma doğruluğu ile elde edilen sonuçların anlaşılması ve sonuçların karar verme mekanizmalarında kullanılması için doğru tahminler gerekmektedir. Referans verisiyle doğrulanarak noktalar referans olarak kullanılarak, sınıflandırılmış görüntünün doğruluğu, görüntünün sınıflandırmasının çalışma alanındaki gerçek sınıflandırmaya ne kadar yakın olduğunu göstermek için oluşturulmuştur. AK/AÖ performansını değerlendirmek için en yaygın doğruluk tahmin parametreleri olan doğruluk (Eşitlik 3.10), Hassasiyet (Hatırlama) (Eşitlik 3.11), Duyarlılık (Eşitlik 3.12), F_1 Puanı (Eşitlik 3.13), Özgünlük değerlendirilmesi (Eşitlik 3.14) ve Kappa İndeks (Eşitlik 3.15) araştırılması yapılmıştır.

Doğruluk (Eşitlik 3.10); Sınıflandırıcının genel doğruluğu, geçerliliği, verimliliği olarak tanımlanmaktadır.

Hassasiyet (Eşitlik 3.11); Sınıflandırıcı tarafından verilen pozitif etiketler ile elde edilen veri etiketlerinin sınıflarla olan uyumudur.

Duyarlılık (Eşitlik 3.12) ; Pozitif etiketlerin tanımlanmasında için sınıflandırıcının geçerliliği ve etkisidir.

F_1 Puanı (Eşitlik 3.13); Verilerin pozitif etiketleri ile sınıflandırıcı tarafından verilenlerle olan ilişkilerdir.

Özgünlük Değerlendirilmesi (Eşitlik 3.14); Bir sınıflandırıcının negatif etiketleri ne kadar etkili bir şekilde tanımladığıdır.

Kappa İndeks (Eşitlik 3.15) ; Sınıflandırıcının yanlış sınıflandırmadan kaçınma yeteneği olarak tanımlanmaktadır.

Bir sınıflandırmanın doğruluğu, doğru tanımlanmış sınıf örneklerinin sayısı (doğru pozitifler), doğru tanınan sınıfa ait olmayan örneklerin sayısı (doğru negatifler) ve yanlış bir şekilde sınıfa atanan (yanlış pozitifler) veya sınıf örnekleri olarak tanınmayan (yanlış negatifler) örnekler ile belirlenmektedir (Sokolova M ve Lapalme G. 2009).

Sınıflandırma algoritmasının performansını değerlendirmede kullanılan metriklerinin hesaplanmasında kullanılan dört terim vardır (Chen et al. 2018; Orhan et al. 2020)

- Doğru Pozitif (DP) (True Positive): Sınıflandırıcı tarafından pozitif olarak tahmin edilen ve gerçek değerinde pozitif olduğu durum. Bu, modelimizin doğru tahmin yaptığı bir durumdur.
- Doğru Negatif (DN) (True Negative): Sınıflandırıcı tarafından negatif olarak tahmin edilen ve gerçek değerinde negatif olduğu durum. Bu, modelimizin doğru tahmin yaptığı bir diğer durumdur.
- Yanlış Pozitif (YP) (False Positive): Sınıflandırıcının pozitif olarak tahmin ettiği fakat gerçek değerinde negatif olduğu durum. Bu, modelimizin yanlış tahmin ettiği bir durumdur.
- Yanlış Negatif (YN) (False Negative): Sınıflandırıcının negatif olarak tahmin ettiği fakat gerçek değerinde pozitif olduğu durum. Bu da modelimizin yanlış tahmin ettiği bir diğer durumdur (Chen ve ark. 2017)

$$\text{Doğruluk} = \frac{(DP+DN)}{(DP+YP+YN+DN)} \quad (3.10.)$$

$$\text{Hassasiyet} = \frac{(DP)}{(DP+YP)} \quad (3.11.)$$

$$\text{Duyarlılık} = \frac{(DP)}{(DP+YN)} \quad (3.12.)$$

$$F_1 \text{ Puanı} = 2 * \frac{(\text{Hassasiyet} * \text{Duyarlılık})}{(\text{Hassasiyet} + \text{Duyarlılık})} \quad (3.13.)$$

$$\text{Özgünlük} = \frac{(DN)}{(DN+YN)} \quad (3.14.)$$


$$\text{Kappa indeks} = \frac{2 * (DP * DN - YN * YP)}{(DP+YP) * (YP+DN) + (DP+YN) * (YN+DN)} \quad (3.15.)$$

4. BULGULAR VE TARTIŞMA

Bu tez çalışmasında, nesne tabanlı sınıflandırma yöntemi kullanılarak uzaktan algılama ile temin edilen uydu görüntülerinden arazi örtüsü/kullanımı sınıflarının belirlenmesinde en iyi sonuçları veren makine öğrenme algoritmalarının performansı araştırılmıştır. Çalışmada veri olarak Göktürk-2, Sentinel 2 ve Landsat 8 uydu platformlarından temin edilen görüntüler kullanılmış olup iki farklı çalışma alanında (Şekil 4.1.) değerlendirmeler yapılmıştır. Bu kısımda ilk olarak seçilen çalışma alanları ve uydu görüntüleri tanıtılmış olup ardından veri ön işleme ve sınıflandırma son olarak da doğruluk analizleri aktarılmaktadır.

4.1. Çalışma Alanları ve Uydu görüntüsü

Çalışmanın ana konusu olan AK/AÖ sınıflandırması için ekili tarım, ekilmemiş tarım, sulak alan, kentsel alan ve çorak sınıflarının makine öğrenme algoritmasında performansı analiz edilmek istenmiştir. Veri olarak Göktürk-2, Sentinel 2 ve Landsat 8 uydu görüntüleri çalışılmıştır. Tercih edilen uydu platformların seçilme nedenleri giriş kısmında anlatılmıştır. Elde edilen veriler doğrultusunda Şekil 4.2 ve 4.3’de verilen çalışma alanlarının seçilmesinde ana etken Türkiye Cumhuriyeti Milli Savunma Bakanlığı Hava Kuvvetleri Komutanlığı’ndan temin edilen Göktürk-2 uydu verilerinin uygun olmamasından (bulutluluk, veri eksikliği vb.) dolayı çalışılmak istenilen sınıflara uygun alanlar belirlenmiştir. Bu amaç doğrultusunda tez kapsamında iki farklı alan (Şekil 4.1) seçilmiştir.




Şekil 4.1. Çalışma alanı.

Tez kapsamında kullanılan Göktürk-2, Sentinel-2, Landsat-8 uydu görüntülerinin her iki çalışma alanı için tarihleri, spektral ve mekânsal özellikleri Tablo 4.1’de verilmiştir. Uydu görüntülerinin seçiminde bulutluluk oranının %5’ten küçük olmasına dikkat edilmiştir.


Tablo 4.1. Çalışmada kullanılan veriler ve özellikleri.

Uydu	Tarih		Spektral	Çözünürlük (m)
	Çalışma 1	Çalışma 2		
Göktürk-2	21.06.2021	02.05.2021	Blue: 0.422-0.512 μm Red: 0.596-0.75 μm Green: 0.5-0.584 μm NIR: 0.762-0.894 μm	5.226
Sentinel2	2.07.2021	22.05.2021	Blue: 0.49 μm Red: 0.665 μm Green: 0.56 μm NIR: 0.842 μm	10
Landsat-8	21.05.2021	04.06.2021	Blue: 0.45-0.51 μm Red: 0.63-0.68 μm Green: 0.52-0.60 μm NIR: 0.84-0.88 μm	15

Çalışma alanı 1 (Şekil 4.2), ekili ve ekili olmayan tarım alanlarının iç içe geçmesi aynı zamanda kentsel alanların özellikle ekili olmayan tarım alanları ile benzerlik göstermesi ve çorak alanlarının da aynı şekilde ekili olmayan tarım alanları ile benzerlik göstermesinden dolayı tercih edilmiştir. Çalışma alanı 2 (Şekil 4.3) ise ekili olan ve ekili olmayan alanların ayrıca kentsel alanların da bulunduğu ve bunlara ek olarak sulak alanların (deniz, göl, akarsu) bulunmasından dolayı tercih edilmiştir.



Şekil 4.2. (a) Göktürk-2 (b) Sentinel-2 (c) Landsat-8 Çalışma Alanı 1.



Şekil 4.3. (a) Göktürk-2 (b) Sentinel-2 (c) Landsat-8 Çalışma Alanı 2.

4.2. Veri Ön işleme

Çalışmada ilk olarak G2K ve L8 uydu görüntüleri için görüntü keskinleştirme işlemi gerçekleştirilmiş olup Sentinel 2 için herhangi bir ön işlem yapılmamıştır. Görüntü keskinleştirme yöntemleri kullanılarak düşük çözünürlüklü multispektral bantların renk bilgisi ve yüksek çözünürlüklü pankromatik (PAN) bantların yüksek mekânsal çözünürlüğünü bir araya getirip yüksek mekânsal çözünürlüklü ve renkli görüntüler elde edilmiştir. Bu çalışma da arazi kullanım sınıflarının daha kolay yorumlanması ve sınıflandırma doğruluğunun artırılması amacı ile Göktürk-2 ve L8 uydusunun düşük mekânsal çözünürlüğe sahip multispektral bantları (kırmızı, yeşil, mavi, yakın kızılötesi) ile yüksek mekânsal çözünürlüğe sahip PAN bandı kullanılarak keskinleştirilmiştir. Bu işlem sonucunda çalışmada G2, S2 ve L8 verileri için sırasıyla 5.26 m, 10 m, 15 m mekânsal çözünürlüğe sahip veriler kullanılmıştır. Uydu görüntüleri temin edilirken, dijital olarak işlenmiş ve bant birleştirme işlemi uygulanmış olarak alınabileceği gibi, her bant ayrı olacak şekilde de temin edilebilir. G2 görüntüsü *.tiff formatında bant birleştirme işlemi önceden yapılmış olarak temin edilmiştir. Ancak Landsat 8 ve Sentinel 2 görüntüleri farklı spektral bantlarda alınmış ve bant birleştirme işlemi uygulanmıştır.

Çalışma alanı olarak seçilen alanlar (Şekil 4.2 ve Şekil 4.3) çerçevesi en küçük olan G2 (20x20 km) uydu görüntüsüne göre belirlendiği için S2 (290x290 km) ve L8 (185x185 km) uydu verileri G2 uydu verisine göre sınırlandırılmıştır ve bu alana uygun olarak kesilmiştir. Çalışmada kullanılan görüntüler maksimum %3 bulutluluk içerecek şekilde seçilmiştir ve bu nedenle iyileştirme amaçlı herhangi bir radyometrik düzeltme işlemine tabi tutulmamıştır. Mevcut bütün görüntülerin projeksiyonunun UTM, Zone 36, datumlarının WGS84 olduğu ve tekrar iz düşürülmeye gerek olmadığı görülmüştür. Ancak görüntüler aynı projeksiyon sistemine ait olduğu halde geometrik uyumsuzluklar fark edilmiş olup S2 ve L8 uydu görüntüsü altlık olarak kullanılmış ve G2 verisinde geometrik düzeltme yapılmıştır.

4.3. Sınıflandırma

Çalışmada nesne tabanlı sınıflandırma yaklaşımı kullanılmış olup, şekil, boyut, ton/reng, doku, desen, ilişkilendirme vb. gibi mekânsal özellikleri dikkate alınarak görüntüler homojen nesnelere ayrılmıştır.


Nesne tabanlı sınıflandırma yönteminde segmentasyon işlemi için çoklu çözünürlüklü segmentasyon algoritması kullanılmıştır. Çoklu çözünürlüklü segmentasyon işleminde parametreler kullanıcı tarafından belirlenir. Bu parametreler ölçek, renk ve şekil parametreleridir. Parametreler mümkün mertebe gerçeğe en yakın değerde girilmelidir. Girilen 3 parametre içinde en önemlisi ölçek parametresidir. Renk ve şekil parametreleri birbirini 1'e tamamlar.

Çoklu çözünürlüklü segmentasyon, nesne yönelimli sınıflandırmanın temelidir. Ölçek, şekil ve renk parametrelerini ayarlayarak çokgen nesneler üretmek için görüntüyü herhangi bir ölçekle bölümlere ayırabiliriz. Çalışmada renk ve şekil parametreleri 0.5 seçilmiş olup ölçek parametreleri G2 verisi üzerinde deneme yanılma yolu ile araştırılarak 10 seçilmiştir. Öncelikle, bölütleme işlemi kullanılarak oluşturulan her bir nesne görüntüsü için tüm katmanların ortalama yerel varyansı hesaplanır. Daha sonra, her nesne görüntüsünden değişim oranı oluşturulur. Değişim oranı indeksten (katman sayısı) büyükse süreç, üretilen her nesnenin değişim oranını ve yerel varyansını hesaplamaya devam eder, aksi takdirde durur. Her iki çalışma alanı için beş ölçek düzeyi uyguladık; sonuç olarak, her seviye için iki ölçek parametresine ihtiyacımız vardı. İlk seviye, büyük ölçekli bir parametre gerektiren daha kaba seviyeli üst sınıf nesneleri sağlamayı amaçlıyordu. Oysa ikinci hiyerarşi, ince ölçekli alt nesneler elde etmek için üretildi; bunun için küçük ölçekli bir parametre gerekiyordu.

Ölçek parametresi, segmentasyon işlemi aşamasında önemli bir yer edinmektedir. Şekil 4.4'te görüleceği gibi ölçek parametresini değiştirerek görüntü nesnelerinin boyutunu da değiştirebiliriz. Segmentasyon nesnenin homojenliği, nesne içindeki piksel değerinin standart sapmasına göre değerlendirilebilirken heterojenlik, nesnenin spektral heterojenliği, şekil heterojenliği veya doku heterojenliği ile tanımlanacağı için nesnenin niteliği, segmentasyon ölçeği tarafından tanımlanan heterojenlik eşliğini aştığında, nesnenin büyümesi durur. Optimizasyondan sonra, her nesnenin iç ağırlıklı heterojenliği en aza indirilir. Heterojenliğin değişimini makul bir aralıkta sınırlayarak, büyük varyansa sahip nesneler birleştirilmez. Bu nedenle, birleştirilmiş nesneler heterojenliği önemli ölçüde değiştirmemelidir. Heterojenlik değişimi, segmentasyon ölçekleriyle ilgilidir ve iyi birleştirme sonuçları elde etmek için heterojenliğin değişimi ölçek parametresinden daha büyük olmamalıdır.

Çalışmada ölçek araştırması için 5'ten 100'e kadar çoklu segmentasyon ölçekleri kullanıldı. Ölçek parametresi için sırasıyla 10, 25, 50, 75, 100 ve 125 arasında değerler verilerek en uygun ölçek parametresi bulunmaya çalışılmıştır. Böylece görüntü farklı bölütleme ölçekleri kullanılarak işlendi ve analiz edildi. Bu çalışmada renk, şekil, pürüzsüzlük ve kompaktlığın etkileri dikkate alınmadı, bu nedenle her segmentasyon ölçeği renk (0,9), şekil (0,1), pürüzsüzlük (0,5) ve kompaktlık (0,5) için aynı ağırlıkları paylaştırdı.

Bölütleme sonuçlarına göre, küçük bir bölütleme ölçeğinin görüntünün aşırı bölütlenmesine neden olduğu, bunun da aşırı çokgen nesnelerin üretileceği ve dolayısıyla, aynı nesne farklı kategorilere ayrılabilmesi fark edildi. Çalışmada makine öğrenme algoritmalarında eğitim amaçlı seçilecek segmentlerin belirlenmesinde aşırı segmentasyon, eğitim örneklerini seçmek için zararlıdır. Büyük bir bölütleme ölçeği için, görüntü sınıflandırma işlemi sırasında heterojenlik artacaktır. İdeal bölütleme ölçeği, farklı bloklar arasındaki farklılıkları gösterebilen bir sonuç elde edecektir, ancak iç homojenlik yüksek olacaktır. Farklı segmentasyon ölçekleri, farklı sayıda nesnenin tanımlanmasına neden olmuştur. Şekil 4.4'te görülebileceği gibi, parçalanmış nesne sayısı 50'lik bir ölçekten 75'lik bir ölçeğe hızla düştü, ancak ölçek 100 ile 125 arasındayken nesne sayısındaki değişim eğilimi sabitlendi. Çalışmada G2 için yapılan ölçek araştırması aynı şekilde hem S2 hem de L8 için yapılmış olup aynı sonuçları bulunmuş olup ölçek parametresi 50 seçilmiştir.



Şekil 4.4. Göktürk2, Ölçek parametresi araştırılması.

Segmentasyon işleminden sonra makine öğrenme algoritmaları için eğitim nesneleri seçilmiştir. Eğitim nesnelerinin her iki çalışma alanı için hangi sınıfta ne kadar temsil edileceği uydu görüntüsü çalışma alanı büyüklüğü ve referans verisindeki sınıfların kapladığı alanın büyüklüğünün veri kümesi (evren) olarak kabul edilmesi ile kullanılan üç ayrı uydu görüntüsünde çalışma alanı 1 (Şekil 4.2) ve çalışma alanı 2 (Şekil 4.3) için belirlenen sınıfları (ekili tarım, ekilmemiş tarım, kentsel, çorak, sulak) eğitim ve toplam segment sayısı Eşitlik 3.4 kullanılarak bulunmuştur ve Tablo 4.2'de verilmiştir.

Tablo 4.2. Her iki çalışma alanı için eğitim ve toplam segment sayısı.

AK/AÖ tip	Segment sayısı (eğitim/toplam) Çalışma Alanı 1			Segment sayısı (eğitim/toplam) Çalışma Alanı 2		
	Göktürk-2	Sentinel-2	Landsat-8	Göktürk-2	Sentinel-2	Landsat-8
Ekili tarım	64/284266	79/154940	157/295468	56/246894	92/181433	81/153400
Ekilmemiş tarım	49/215733	90/177596	161/304399	61/27813	40/79039	49/93043
Kentsel	13/59834	21/42354	8/14952	10/44722	5/9025	5/8674
Çorak	70/311048	73/144823	35/65282	-	-	-
Sulak	-	-	-	23/103461	13/26542	15/27785

Bu araştırmada, Çalışma 1 (Şekil 4.2) ve Çalışma 2 (Şekil4.3) için eğitim örnekleri G2-S2-L8 için toplam 150 adet olarak bulunmuştur. Her iki çalışma alanı için referans verilerinden sınıflara göre segmentlerin oranlaması ile bulunan örneklem sayısı dağılımları her uydu görüntüsünde farklılık göstermektedir. Bunun ana sebebi uydu görüntülerin farklı mekânsal çözünürlüğe sahip olması ve buna bağlı olarak her uydu görüntüsünde farklı sayıda segment sayısı üretilmesi gösterilebilir. Eğitim segmentleri seçildikten sonra her iki çalışma alanı için SVM, K-NN, Bayess, DT, RT makine öğrenme algoritmaları ile AK/AÖ sınıflandırılması yapılmış olup sınıflandırma görüntüleri Şekil 4.5 ve 4.6’te verilmiştir. Çalışma alanları için, ekili tarım (yeşil), ekilmemiş tarım (sarı), kentsel (kırmızı), çorak (kahverengi) ve sulak (mavi) dâhil olmak üzere AK/AÖ sınıflandırması yapılmıştır.


Çalışma alanı 1; ekili tarım, ekilmemiş tarım, kentsel ve çorak olmak üzere dört bölgeye, Çalışma alanı 2; ekili tarım, ekilmemiş tarım, kentsel, sulak olmak üzere dört bölgeye dayalı olarak görsel olarak yorumlanmıştır (Şekil 4.5-4.6). Referans verisi ile görsel inceleme sonucunda sınıflandırılmış görüntülerde genel olarak G2 uydusu, S2 ve L8 uydularına göre daha iyi performans gerçekleştirmiştir. Çalışmada 3 farklı mekânsal özelliğe sahip uydu görüntülerinin AK/AÖ sınıflandırmasında performansları analiz edildiği için görsel inceleme her uydu platformları için ayrı ayrı aktarılmıştır. Ayrıca görsel inceleme sonrasında istatistiksel olarak karşılaştırılmalı analiz aktarılacaktır.

Görsel inceleme ilk olarak Çalışma alanı 1’de G2 uydusu için gerçekleştirilmiş olup tüm makine öğrenme algoritmaları için her sınıf atamaları detaylı bir şekilde incelenmiştir. Görsel inceleme sonucunda kullanılan makine öğrenme algoritmalarının sınıflandırılmış görüntüler arasında farklılık mevcuttur. Bu farklılıklar incelendiğinde ham görüntü ile en yakın benzerliği SVM algoritması vermiştir. Genel olarak G2 uydu görüntüsü için en başarılı olduğu sınıf ekili ve ekili olmayan tarım arazisidir. Kentsel alanlarda ise genel olarak başarılı olsa da yol ağlarında çorak ve ekili olmayan tarım arazilileri ile karıştığı gözlemlenmiştir. Çorak arazilerin yoğunlukta olduğu bölgelerde komşu segmentlerin genellikle ekili olmayan tarım arazisi olması çorak arazilerin sınıflandırılmasında olumsuzluğa neden olmuştur. Görüntü %98 oranında bulutsuz bir yapıda olmasında rağmen bulut olan bölge kentsel alan olarak sınıflandırılmıştır. Kentsel alanların etrafında bulunan küçük yapıdaki ekili ve

ekili olmayan tarım arazilerinin genelinin kusursuza yakın olarak doğru sınıflandırıldığı gözlemlense de yol ağlarının ekilmemiş tarım arazine atanması bu algoritmanın dezavantajını oluşturmaktadır. Görsel inceleme sonucunda ikinci en başarılı algoritma K-NN belirlenmiştir. K-NN algoritması da genel olarak ekili tarım arazilerini doğru sınıflandırırken ekilmemiş tarım ile çorak arazide karışmalar mevcut iken kentsel alanların çorak araziler ile karıştığı gözlemlenmiştir. Görüntüdeki bulutlu bölgenin SVM algoritması gibi kentsel sınıfa atandığı görülmüştür. Bu kısımda daha az başarılı olarak görülen Bayess ile RT algoritmaları birbirileri ile çok yüksek oranda benzerlik göstermiştir. Bu iki algoritma genel olarak çorak arazi ile kentsel arazilerin karıştığı gözlemlenmiş ayrıca ekilmemiş tarım arazilerinin azımsanmayacak sayıda ekili tarım arazisi sınıfına atandığı gözlemlenmiştir. Kentsel ve yol ağlarının diğer algoritmalar ile benzer olduğu gözlemlenmiştir. Bayess ve DT algoritmaları da önceki iki algoritma gibi bulutlu kısmı kentsel sınıfa atamıştır. Son olarak RT algoritması görsel inceleme sonucunda en başarısız algoritma olarak tespit edilmiştir. Bu algoritma diğer algoritmalarla nazaran ekili tarım arazilerinin çoğunluğunu doğru sınıflandırsa da ekili olmayan tarım arazilerinin büyük bir kısmını ekili tarım arazisi sınıfına atamıştır. Doğru sınıfa atanan ekilmemiş tarım arazilerinin piksellerinin daha belirgin olması doğru sınıflandırmada etkili olurken diğer sınıflar ile karışması muhtemel olan ekilmemiş tarım arazilerinde ise algoritma başarısız sonuç vermiştir. Genel olarak algoritma yol ağlarını doğru sınıflandırırken kentsel alanları olmayan özellikle çorak arazilerini bu sınıfa atamıştır. Genel olarak 1. Çalışma alanı için SVM algoritması başarılı görünmekte olup ekili tarım arazilerinin büyük bir kısmı tüm algoritmalarda doğru sınıflandırılmıştır. Ayrıca ana yol hatlarının neredeyse tüm algoritmalarda doğru sınıflandırılmış olsa da toprak yollarda Bayess ve DT daha başarılı olmuştur. Bunun sebebi olarak çorak ve ekili olmayan tarım arazilerinin kentsel sınıf ile karışmış olması gösterilebilir. Bu çalışma alanı için görsel inceleme sonucunda en başarılı görünen SVM algoritmasında ise ara yolların bazılarının ekilmemiş tarım arazisi ile karışmış olup diğer sınıflarda bu karışım az miktarda olduğu gözlemlenmiştir. Çalışma alanı 1 için S2 uydu görüntüsüne ait sınıflandırılmış görüntüler görsel olarak incelendiğinde en başarılı algoritmanın G2 uydusu gibi SVM algoritması göstermiştir. SVM algoritması genel olarak ekili tarım ve ekili olmayan tarım arazilerinde yüksek oranda başarılı olmuştur. Kentsel alanlarda bu başarı paralellik gösterse de ana yollara göre ara yollarda başarı oranı düşük olmuştur. SVM algoritması S2 görüntüsünde çorak ve ekili olmayan tarım arazilerinin yoğunlukta fakat ekili tarımın azınlıkta olduğu alanlarda ekili tarım arazilerini doğru sınıflandırmada zorluk çekmiştir. S2 görüntüsünde ikinci en başarılı algoritma görsel inceleme sonucunda K-NN ve Bayess algoritması olduğu görülmektedir. Ayrıca bu iki algoritma görsel olarak incelendiğinde büyük bir bölümün paralellik gösterdiği görülmüştür. K-NN ve Bayes algoritmasının ekili tarım alanları ile ekilmemiş tarım alanlarında daha başarılı olmasına rağmen kentsel alanlarda SVM ye göre daha az başarılı olduğu diğer algoritmalarla göre ise daha yüksek sonuç verdiği gözlemlenmiştir. S2 için en az başarılı olan DT ve RT algoritmaları da birbiri arasında oldukça paralellik göstermiştir. Bu iki algoritma diğer algoritmalarla göre kentsel alanlarda ve çorak arazilerde düşük başarı göstermiştir. Ayrıca çorak alanlar ile ekilmemiş tarım alanlarını karıştırmıştır. Genel olarak S2 uydu görüntüsünde tüm

algoritmalar tarım alanlarını doğru sınıflandırma gösterse de ekilmemiş tarım arazilerinin çorak arazilerle karıştığı saptanmıştır. Kentsel alanlarda ise özellikle Bayess ve DT diğerlerine göre daha düşük performans göstermiş olup genel olarak S2 için beş algoritma arasında tutarlılık görülmüştür.

Çalışma alanı 1 için L8 uydu görüntüsüne ait sınıflandırılmış görüntüler arasında benzerlik görülmemiş olup her algoritma sonucu birbirinden farklı sonuç sınıflandırması gerçekleştirilmiştir. L8 uydu görüntüsü için en iyi algoritma görsel inceleme sonucunda K-NN olarak belirlenmiştir. K-NN algoritmasında ekili tarım araziler orta düzeyde başarılı olurken diğer algoritmalarda ekili tarım arazileri ile özellikle çorak arazilerin çok fazla karıştığı gözlemlenmiştir. Ayrıca kentsel alanlar ile çorak arazilerin de karıştığı gözlemlenirken kentsel alanlarda sınıflandırılan yol ağlarının sınıflandırılması başarılı görülmüştür. Diğer iki uydu görüntüsünde en başarılı görülen SVM algoritması L8 uydu görüntüsünden ikinci en başarılı algoritma görülmüştür. Fakat SVM algoritması çorak arazilerinin neredeyse tamamını ekilmemiş tarım arazisi ile karıştırırken yol ağlarını da ekilmemiş tarım arazisi olarak sınıflandırılmıştır. Kentsel alanlarda ise SVM'nin başarısı orta düzey bulunmuştur. Çalışma alanı 1 için diğer üç algoritmaları incelendiğinde başarısız bulunmuştur. Bu üç algoritma arasında ise en başarısız DT olarak tespit edilmiştir. Bayess algoritması ise kentsel alanlarda diğer algoritmalara göre daha başarılı bulunmuştur. Çalışma alanı 1 için genel değerlendirme yapıldığında en etkili sonuç G2 uydu görüntüsünde SVM algoritması sınıflandırılması olarak gözlemlenmiştir. G2 uydusunda diğer algoritmalar incelendiğinde daha iyi performans beklenirken S2 uydusuna ait SVM sınıflandırılması ikinci en başarılı olarak tespit edilmiştir. Fakat S2 SVM sınıflandırılmasında çorak arazilerin ekili olmayan tarım arazileri ile karışması olumsuz olarak belirlenmiştir. Bu çalışma alanı için L8 uydu görüntüsüne göre tüm algoritmaları daha başarısız bulunmuştur.



Şekil 4.5. Çalışma alanı 1 için sınıflandırılmış AK/AÖ görüntüsü.

Görsel inceleme daha sonra Çalışma alanı 2’de (Şekil4.6.) G2 uydusu için gerçekleştirilmiş olup tüm makine öğrenme algoritmaları için her sınıf atamaları detaylı bir şekilde incelenmiştir. Görsel inceleme sonucunda kullanılan makine öğrenme algoritmalarının sınıflandırılmış görüntüleri Çalışma alanı 1’e göre tüm algoritmalar arasında farklılıklar belirsizdir.

Çalışma alan 2 için sınıflandırılmış görüntüler incelendiğinde ham görüntü ile en yakın benzerliği SVM algoritması vermiştir. Genel olarak G2 uydu görüntüsü için en başarılı olduğu sınıflar ekili ve ekili olmayan tarım arazisi ve sulak alanlardır. Kentsel alanlarda ise genel olarak başarılı olsa da yol ağlarının ekili olmayan tarım arazileri ile karıştığı gözlemlenmiştir. Ekilmemiş tarım arazilerin yoğunlukta olduğu bölgelerde komşu segmentlerin genellikle ekili tarım arazisi olması sınıflandırılmada olumsuzluğa neden olmuştur. Kentsel alanların etrafında bulunan küçük yapıdaki ekili ve ekili olmayan tarım arazilerinin genelinen kusursuza yakın olarak doğru sınıflandırıldığı gözlemlenmiştir.

Görsel inceleme sonucunda ikinci en başarılı algoritma K-NN belirlenmiş olup SVM ile belirsizlikleri çok az bulunmuştur. K-NN algoritması da genel olarak ekili tarım arazilerini doğru sınıflandırırken ekilmemiş tarım ile kentsel arazilerin karıştığı gözlemlenmiştir. Bu çalışma alanında daha az başarılı olarak görülen Bayess, RT ve DT algoritmaları birbirileri ile çok yüksek oranda benzerlik göstermiştir. Bu üç algortmada, genel olarak ekilmemiş tarım arazisi ile kentsel arazilerin az oranda karıştığı gözlemlenmiş ayrıca sulak arazilerin oldukça başarılı doğru sınıfa atandığı gözlemlenmiştir. Kentsel ve yol ağlarının diğer algoritmalar ile benzer olduğu gözlemlenmiştir. Genel olarak algoritma ekili ve ekilmemiş tarım arazileri oldukça yüksek oranda doğru sınıflandırırken kentsel alanlar da bazı olumsuzluklar gözlemlenmiştir. Ayrıca ana yol hatlarının neredeyse tüm algoritmalarda benzer sınıflandırma yaptığı görülmüş ek olarak sulak alanlarında tüm algoritmalarda kusursuza yakın doğru sınıflandırıldığı belirlenmiştir.


Çalışma alanı 2 için S2 uydu görüntüsüne ait sınıflandırılmış görüntüler görsel olarak incelendiğinde en başarılı algoritmanın G2 uydusu gibi SVM algoritması göstermiştir. SVM algoritması genel olarak ekili tarım arazilerinde yüksek oranda başarılı olmuştur. Fakat ekilmemiş tarım arazilerinin ekili tarım arazisi olarak sınıflandırılan segment sayısı oldukça yüksektir. Kentsel alanlarda ana yollar orta düzey başarılı ara yollarda ise başarı oranı düşük olmuştur. SVM algoritması S2 görüntüsünde sulak alanlar neredeyse tamamı doğru sınıflandırılmış olup kentsel alanlar genel itibari ile yüksek doğruluk göstermiştir.

S2 görüntüsünde görsel inceleme sonucunda diğer algoritmalarda başta RT, DT ve Bayess olmak üzere kentsel alanlar çok fazla bulunmuş olup bu yanlış atamalar genel olarak ekilmemiş tarım arazilerini kapsamaktadır. Ayrıca bu üç algoritma görsel olarak incelendiğinde büyük bir bölümün paralellik gösterdiği görülmüştür. K-NN ve Bayes algoritmasının ekili tarım alanları ile ekilmemiş tarım alanlarında daha başarılı olmasına rağmen kentsel alanlarda SVM ye göre daha az başarılı olduğu diğer algoritmalarla göre ise daha yüksek sonuç verdiği gözlemlenmiştir.

S2 için en az başarılı olan DT ve RT algoritmaları da birbiri arasında oldukça paralellik göstermiştir. Bu iki algoritma diğer algoritmalara göre kentsel alanlarda ve ekilmemiş tarım arazilerinde düşük başarı göstermiştir. Genel olarak S2 uydu görüntüsünde tüm algoritmalar tarım alanlarını doğru sınıflandırma gösterse de ekilmemiş tarım arazilerinin kentsel arazilerle karıştığı saptanmıştır. Kentsel alanlarda ise özellikle Bayess ve DT diğerlerine göre daha düşük performans göstermiş olup genel olarak S2 için SVM hariç diğer dört algoritma başarısız bulunmuştur.

Çalışma alanı 2 için L8 uydu görüntüsüne ait sınıflandırılmış görüntüler arasında SVM ve K-NN kendi arasında tutarlı iken DT ve RT kendi arasında benzerlik göstermiş olup Bayess diğer algoritmalarından farklı sonuç sınıflandırması gerçekleştirilmiştir. L8 uydu görüntüsü için en iyi algoritma görsel inceleme sonucunda SVM olarak belirlenmiştir. SVM ve K-NN algoritmasında ekili tarım araziler yüksek düzeyde başarılı olurken diğer algoritmalarda ekili tarım arazileri ile özellikle kentsel arazilerin karıştığı gözlemlenmiştir. Ayrıca kentsel alanlarda sınıflandırılan yol ağlarının Bayess sınıflandırılmasında başarılı görülmüştür fakat Bayess algoritmasında kentsel alanların çoğu yanlış sınıflandırılmış olup ekilmemiş tarım arazileri ataması oldukça düşük doğruluktadır. Sulak alanlarda tüm algoritmalar doğru bir şekilde sınıflandırılırken DT ve RT algoritmaları bazı ekilmemiş arazileri sulak sınıflandırmasına atamıştır.

Çalışma alanı 2 için genel değerlendirme yapıldığında en etkili sonuç G2 uydu görüntüsünde SVM algoritması gelirken G2 uydusunda diğer algoritmalar incelendiğinde diğer uydu görüntülerine göre daha iyi performans sağlanmış olup S2 SVM sınıflandırılması da oldukça başarılı görülmüştür. Fakat S2 SVM sınıflandırılmasında çorak arazilerin ekili olmayan tarım arazileri ile karışması olumsuz olarak belirlenmiştir. Bu çalışma alanı için L8 uydu görüntüsünde SVM ve K-NN algoritmaları orta düzeyde başarılı bulunurken diğer algoritmalar başarısız görülmüştür. Üç uydu görüntüsünde tüm algoritmalar sulak alanları neredeyse tamamını doğru sınıflandırılırken L8 uydu görüntüsünde sulak alanlarla benzerlik gösteren ekilmemiş tarım arazileri sulak sınıfına atandığı tespit edilmiştir.



Şekil 4.6. Çalışma alanı 2 için sınıflandırılmış AK/AÖ görüntüsü.

4.4. Doğruluk Analizi Değerlendirmesi

Sınıflandırma işleminden sonra, sınıfların gerçek uzay ile uyumluluğunu belirlemek için bir doğruluk analizi yapılmıştır. Doğruluk analizi, sınıflandırmanın doğruluğunu ve güvenilirliğini ölçmek için son adımdır. Bu tez kapsamında, doğruluk analizi için iki yöntem belirlenmiştir. İlk olarak sınıflandırmanın yapıldığı eCognition Developer yazılımında TTA maskesine dayalı bir hata matrisi kullanarak sınıflandırılmış veriler için bir doğruluk değerlendirme gerçekleştirilmiştir. Seçilen test alanlarının referans değerleri ile sınıflandırma sonucu karşılaştırılarak bir karışıklık hata matrisi üretilmiş ve sınıflandırma kalitesi test edilmiştir. Çalışma alanı 1 ve 2 için doğruluk analizinde hata matrisi geliştirilmiş olup genel doğruluk, kullanıcı doğruluğu, üretici doğruluğu ve kappa katsayısı analiz edilmiş ve Tablo 4.3 ve 4.4'te verilmiştir.

Tablo 4.3. Çalışma alanı 1 için TTA maskesine dayalı doğruluk analizi.

Sınıf		Ekili tarım		Ekilmemiş tarım		Kentsel alan		Çorak		Genel Doğruluk	Kappa Katsayısı
Algoritma	Uydu	KD	ÜD	KD	ÜD	KD	ÜD	KD	ÜD		
SVM	G2	0.981	0.985	0.884	0.745	0.895	0.748	0.882	0.846	0.98	0.95
	S2	0.970	0.925	0.810	0.846	0.830	0.846	0.781	0.802	0.96	0.93
	L8	0.848	0.866	0.902	0.886	0.726	0.820	0.810	0.762	0.86	0.85
K-NN	G2	0.892	0.902	0.896	0.912	0.948	0.922	0.824	0.816	0.91	0.89
	S2	0.870	0.812	0.748	0.814	0.918	0.894	0.798	0.822	0.93	0.91
	L8	0.848	0.852	0.864	0.878	0.766	0.802	0.896	0.924	0.88	0.87
Bayess	G2	0.942	0.926	0.878	0.864	0.712	0.784	0.898	0.882	0.79	0.76
	S2	0.792	0.812	0.856	0.893	0.912	0.903	0.876	0.894	0.85	0.83
	L8	0.836	0.868	0.857	0.901	0.942	0.913	0.792	0.824	0.86	0.86
DT	G2	0.884	0.786	0.774	0.896	0.862	0.806	0.810	0.826	0.93	0.92
	S2	0.938	0.983	0.965	0.949	0.847	0.871	0.904	0.918	0.94	0.94
	L8	0.826	0.834	0.891	0.889	0.846	0.795	0.901	0.946	0.82	0.80
RT	G2	0.888	0.902	0.798	0.842	0.862	0.846	0.946	0.886	0.89	0.88
	S2	0.886	0.898	0.835	0.865	0.869	0.951	0.926	0.948	0.86	0.86
	L8	0.922	0.896	0.941	0.862	0.752	0.789	0.802	0.862	0.81	0.80

*ÜD: Üretici doğruluğu, KD: kullanıcı Doğruluğu,

Çalışma alanı 1 için genel doğruluk Tablo 4.3 incelendiğinde tüm algoritmalar arasında üç uydu görüntüsünün ortalama genel doğruluğuna göre SVM (%93) en iyi sınıflandırma algoritması ve Bayess'in (%82) en kötü performans gösterdiği bulunmuştur. SVM'nin üç uydu görüntüsünde performansı incelendiğinde sırasıyla G2, S2 ve L8 başarılı olmuştur. Ayrıca bu üç uydu görüntüsünde SVM algoritmasının en iyi ekili tarım arazilerini tespit ettiği belirlenmiştir. Ancak, üç veri setinde SVM algoritmasında göreceli performanslarında herhangi bir eğilim gözlemlenmemiştir. Görünüşe göre sonuçlar, nesne tabanlı sınıflandırma yaklaşımının, yüksek çözünürlüklü veri setinin (G2), çözünürlüğü nispeten daha düşük olan veri setlerinden (S2 ve L8) daha iyi performans gösterdiği tespit edilmiştir. Üretici doğruluğu ve kullanıcı doğruluğu Tablo 4.3'de görüldüğü üzere ekili tarım ve ekilmemiş tarım alanlarında yüksek oran sağlarken çorak arazilerde nispeten daha düşük oran sağlamıştır. G2 uydu görüntüsünde SVM algoritması, ekili araziler için en yüksek kullanıcı doğruluğuna sahiptir (%98). Genel olarak SVM algoritması, diğer algoritmalarla göre üretici doğruluğu ve kullanıcı doğruluğu açısından

daha yüksek değere sahiptir. Ayrıca sonuçlar üretici doğruluğu performansının kullanıcı doğruluğuna göre daha iyi olduğunu göstermektedir. Sonuçları sınıf bazında analiz edilecek olunursa ekili tarım ve ekilmemiş tarım arazileri iyi performans seyrederken çorak ve kentsel alanlar daha düşük performans sergilemiştir.

Tablo 4.4. Çalışma alanı 2 için TTA maskesine dayalı doğruluk analizi.

Sınıf		Ekili tarım		Ekilmemiş tarım		Kentsel alan		Sulak		Genel Doğruluk	Kappa Katsayısı
Algoritma	Uydu	KD	ÜD	KD	ÜD	KD	ÜD	KD	ÜD		
SVM	G2	0.988	0.929	0.886	0.932	0.793	0.942	0.953	0.904	0.98	0.96
	S2	0.930	0.987	0.817	0.854	0.991	0.819	0.981	0.945	0.96	0.97
	L8	0.857	0.995	0.919	0.917	0.913	0.989	0.991	0.952	0.95	0.91
K-NN	G2	0.860	0.959	0.991	0.900	0.972	0.792	0.826	0.943	0.93	0.89
	S2	0.922	0.946	0.836	0.838	0.814	0.931	0.993	0.926	0.92	0.88
	L8	0.951	0.983	0.832	0.966	0.900	0.957	0.925	0.986	0.96	0.85
Bayess	G2	0.974	0.961	0.793	0.825	0.819	0.826	0.974	0.845	0.83	0.80
	S2	0.891	0.982	0.796	0.812	0.965	0.939	0.926	0.978	0.90	0.91
	L8	0.862	0.833	0.816	0.790	0.881	0.928	0.995	0.944	0.92	0.85
DT	G2	0.963	0.986	0.919	0.806	0.983	0.823	0.929	0.980	0.98	0.92
	S2	0.870	0.957	0.842	0.843	0.975	0.801	0.980	0.923	0.91	0.94
	L8	0.848	0.872	0.859	0.902	0.937	0.911	0.879	0.858	0.89	0.85
RT	G2	0.960	0.813	0.887	0.840	0.805	0.826	0.930	0.938	0.92	0.93
	S2	0.807	0.853	0.787	0.810	0.911	0.837	0.913	0.984	0.86	0.87
	L8	0.897	0.819	0.878	0.825	0.858	0.783	0.880	0.859	0.83	0.86

*ÜD: Üretici doğruluğu, KD: Kullanıcı Doğruluğu

Çalışma alanı 2 için genel doğruluk Tablo 4.4 incelendiğinde tüm algoritmalar arasında üç uydu görüntüsünün ortalama genel doğruluğuna göre SVM (%96) en iyi sınıflandırma algoritması ve Bayess'in (%88) en kötü performans gösterdiği bulunmuştur. SVM'nin üç uydu görüntüsünde performansı incelendiğinde sırasıyla G2, L8 ve S2 başarılı olmuştur. Ayrıca bu üç uydu görüntüsünde SVM algoritmasının en iyi ekili tarım arazilerini ve sulak arazileri tespit ettiği belirlenmiştir. Sonuçlar, G2 ve S2 için SVM, L8 için K-NN'nin daha iyi performans gösterdiği tespit edilmiştir. Fakat S2'de tüm algoritmalar ekilmemiş tarım arazilerinde en düşük performans sergilemiştir. Üretici doğruluğu ve Kullanıcının doğruluğu Tablo 4.4'te görüldüğü üzere ekili tarım ve sulak alanlarda yüksek oran sağlarken ekilmemiş tarım arazilerde ise nispeten daha düşük oran sağlanmıştır. Sulak alanlarda neredeyse tüm algoritmalar tüm veri setlerinde başarılı iken L8 için DT ve RT düşük performans göstermiştir. Sonuçlar bu çalışma alanı için kullanıcı doğruluğu performansının üretici doğruluğuna göre daha iyi olduğunu göstermektedir. Sonuçları sınıf bazında analiz edilecek olunursa ekili tarım ve sulak alanlar iyi performans seyrederken ekilmemiş tarım ve kentsel alanlar daha düşük performans sergilemiştir.

Ayrıca tez çalışmasında sınıflandırma sonrası doğruluk değerlendirmesi için rastgele örneklenmiş noktalar oluşturularak referans verileriyle karşılaştırmalı analiz yapılmıştır. Bu amaç doğrultusunda referans verisinde noktalar belirlenmiş ve referans noktaları daha sonra aynı konumlardaki sınıflandırma sonuçlarıyla karşılaştırılmıştır. Bu noktaların konumlarının doğruluğunu test etmek için CBS yazılımında rastgele noktalar atanmıştır. Rastgele atanacak nokta sayısını

belirlemek için oluşturulan parçalara göre örneklem ve örneklem uzayına göre nokta sayısı belirlenmiştir. Referans verisiyle doğrulanmış noktalar referans olarak kullanılarak, sınıflandırılmış görüntünün doğruluğu, görüntünün sınıflandırmasının çalışma alanındaki gerçek sınıflandırmaya ne kadar yakın olduğunu göstermek için oluşturulmuştur. AK/AÖ performansını değerlendirmek için en yaygın doğruluk tahmin parametreleri olan doğruluk (Eşitlik 3.10), Hassasiyet (Hatırlama) (Eşitlik 3.11), Duyarlılık (Eşitlik 3.12), F_1 Puanı (Eşitlik 3.13), Özgünlük değerlendirilmesi (Eşitlik 3.14) ve Kappa İndeks (Eşitlik 3.15) araştırılması yapılmıştır. İlk olarak referans noktalarının sayısını belirlemek için Eşitlik 3.4 kullanılmış olup örneklem büyüklüğü için çalışma alanlarının boyutu (38496.80 km²) ile oluşan segment sayısı kullanılarak referans noktaları (384) belirlenmiştir. Daha sonra çalışma alanı 1 için, ekili tarım, ekili olmayan tarım, kentsel alan, çorak; çalışma alanı 2 için ise, ekili tarım, ekili olmayan tarım, kentsel alan, sulak alan olmak üzere sınıflara uygun referans noktaları sınıflandırılmış vektöre veriler ile karşılaştırılmış Tablo 4.5 ve 4.6’te verilmiştir.

Tablo 4.5. Çalışma alanı 1 için makine öğrenme algoritmalarının doğruluk analizi.

Algoritma	Uydu	DP	DN	YP	YN	Doğruluk	Hassasiyet	Duyarlılık	F1 Puanı	Özgünlük	Kappa İndeks
SVM	G2	198	164	10	12	94.27%	95.19%	94.29%	94.74%	94.25%	88.45%
	S2	188	162	20	14	91.15%	90.38%	93.07%	91.71%	89.01%	82.21%
	L8	149	145	59	31	76.56%	71.63%	82.78%	76.80%	71.08%	53.37%
K-NN	G2	184	159	24	17	89.32%	88.46%	91.54%	89.98%	86.89%	78.56%
	S2	172	168	36	8	88.54%	82.69%	95.56%	88.66%	82.35%	77.20%
	L8	152	151	56	25	78.91%	73.08%	85.88%	78.96%	72.95%	58.09%
Bayess	G2	158	153	50	23	80.99%	75.96%	87.29%	81.23%	75.37%	62.16%
	S2	163	155	45	21	82.81%	78.37%	88.59%	83.16%	77.50%	65.74%
	L8	142	137	66	39	72.66%	68.27%	78.45%	73.01%	67.49%	45.57%
DT	G2	155	151	53	25	79.69%	74.52%	86.11%	79.90%	74.02%	59.59%
	S2	172	160	36	16	86.46%	82.69%	91.49%	86.87%	81.63%	72.96%
	L8	135	132	73	44	69.53%	64.90%	75.42%	69.77%	64.39%	39.40%
RT	G2	145	140	63	36	74.22%	69.71%	80.11%	74.55%	68.97%	48.68%
	S2	170	155	38	21	84.64%	81.73%	89.01%	85.21%	80.31%	69.28%
	L8	139	135	69	41	71.35%	66.83%	77.22%	71.65%	66.18%	43.01%

Üç uydu görüntüsünde beş algoritma için doğruluk, hassasiyet, duyarlılık, F1 puanı, özgünlük, Kappa katsayılar Tablo 4.5’te ve Tablo 4.6 ‘da listelenmiştir. AK/AÖ için nesne tabanlı yaklaşım ile makine öğrenmesi algoritmalarının performans sonuçları irdelendiğinde, çıkarım modelinin nesne tabanlı sınıflandırması için G2 uydu görüntülerinin Sentinel ve Landsat uydu görüntülerinden daha yüksek performans gösterdiğini göstermektedir. Çalışma alanı 1 için G2 en yüksek %94.27 (SVM), S2 en yüksek %91.15 (SVM) ve L8 %78.91 (K-NN) performans göstermiştir. Çalışma alanı 2 için ise G2 en yüksek %90.63 (SVM), S2 en yüksek %91.15 (SVM) ve L8 %90.36 (K-NN) performans göstermiştir. Çalışma alanı 1 en düşük oranlar incelendiğinde G2 için %74.22 (RT), S2 için %82.81 ve L8 için %69.53 performans göstermiş olup G2 ve S2 bu çalışma alanı için başarılı bulunmuş fakat L8 başarılı bulunmamıştır. Çalışma alanı 2’de en düşük oran G2 için %91.67 (RT), S2 için %84.90 ve L8 için %87.76 (Bayess) performans göstermiş olup G2 genel olarak en iyi performansı göstermiştir.

Tablo 4.6. Çalışma alanı 2 için makine öğrenme algoritmalarının doğruluk analizi.

Algoritma	Uydu	DP	DN	YP	YN	Doğruluk	Hassasiyet	Duyarlılık	F1 Puanı	Özgünlük	Kappa İndeks
SVM	G2	199	171	9	5	96.35%	95.67%	97.55%	96.60%	95.00%	92.67%
	S2	185	163	23	13	90.63%	88.94%	93.43%	91.13%	87.63%	81.20%
	L8	183	163	25	13	90.10%	87.98%	93.37%	90.59%	86.70%	80.17%
K-NN	G2	190	171	18	5	94.01%	91.35%	97.44%	94.29%	90.48%	88.01%
	S2	180	163	28	13	89.32%	86.54%	93.26%	89.78%	85.34%	78.64%
	L8	185	162	23	14	90.36%	88.94%	92.96%	90.91%	87.57%	80.67%
Bayess	G2	192	168	16	8	93.75%	92.31%	96.00%	94.12%	91.30%	87.46%
	S2	175	157	33	19	86.46%	84.13%	90.21%	87.06%	82.63%	72.89%
	L8	178	159	30	17	87.76%	85.58%	91.28%	88.34%	84.13%	75.49%
DT	G2	189	167	19	9	92.71%	90.87%	95.45%	93.10%	89.78%	85.38%
	S2	173	156	35	20	85.68%	83.17%	89.64%	86.28%	81.68%	71.34%
	L8	182	163	26	13	89.84%	87.50%	93.33%	90.32%	86.24%	79.66%
RT	G2	186	166	22	10	91.67%	89.42%	94.90%	92.08%	88.30%	83.30%
	S2	173	153	35	23	84.90%	83.17%	88.27%	85.64%	81.38%	69.74%
	L8	177	161	31	15	88.02%	85.10%	92.19%	88.50%	83.85%	76.04%

5. SONUÇLAR VE ÖNERİLER

Bu tez kapsamında Göktürk-2 uydusunun literatürde sıklıkla kullanılan Landsat 8 ve Sentinel-2 uydu görüntüleriyle karşılaştırılması yapılmış olup, son zamanlarda çalışmalarda sıklıkla kullanılan makine öğrenmesinin farklı uydu görüntüleri üzerinde ki performansları araştırılmıştır.

Mekânsal çözünürlüğün AK/AÖ çalışmalarında etkisi incelenmiş olup, sırasıyla mekânsal çözünürlükler Göktürk-2'nin 2.56 m, Sentinel-2 10 m, Landsat 8'in 15m'dir. Çözünürlük artıkcâ örneklem sayısının da artırılması gerekmektedir Çalışma alanı 1'de Göktürk-2 görüntüsünde ki bulut altı yerin beş farklı algortmada kentsel alan olarak sınıflandırılmıştır. Çözüm olarak ESP aracı kullanımı, kullanıcıdan kaynaklı hataların (örneklem seçimi) önlenmesine yardımcı olabilir. Bu sayede örneklem kümeleri otomatik olarak belirlenebilmektedir.

Makine öğrenmesinde kullanılan destek vektör makineleri (SVM), K- En yakın komşuluk (K-NN), Bayess, Karar ağaçları (DT), Rastgele orman (RF) gibi ileri tekniklerin uygulanması ve sınıflandırma süreçlerinde veri madenciliğinin kullanılması, daha kısa sürede daha doğru sınıflandırma sağlamaktadır.

Görsel inceleme sonucunda her iki çalışma alanı için Göktürk-2 uydusu SVM algoritması daha yüksek sonuç vermiştir. TTA maskesine dayalı doğruluk analizinde SVM algoritmasının Göktürk-2 (%98) ve Sentinel-2 (%96) uydularında diğer algortmalara göre daha başarılı sonuç vermiş olup, Landsat-8 de K-NN(%88) algoritmasının performansının SVM (%88)'den daha yüksek olduğu tespit edilmiştir. Çalışma alanı 2 için genel değerlendirme yapıldığında en etkili sonuç G2 uydu görüntüsünde SVM (%98) algoritması olmuştur. Göktürk-2 için diğer dört algortma incelendiğinde Landsat 8 ve Sentinel-2 uydu görüntülerine göre daha iyi performans sağlamıştır.

Seçilen uydular ve kullanılan yöntemler doğrultusunda en başarılı sonucu her iki çalışma alanı içinde Göktürk-2 uydusu SVM algoritmasının göstermiş olduğu tespit edilmiştir.

Bu çalışma sonucunda Türkiye'nin kendi uydusu olan G2; pankromatik ve multispektral mekânsal çözünürlüklerinin yüksek olmasından, AK/AÖ çalışmaları dışında pek çok çalışmada kullanımı mümkündür.

KAYNAKLAR

- Abdi, A. M. (2020). Land Cover And Land Use Classification Performance Of Machine Learning Algorithms In A Boreal Landscape Using Sentinel-2 Data. *Giscience & Remote Sensing*, 57(1), 1-20.
- Abujayyab, S. K., Karas, I., Akbulut, C., & Tellier, V. Ship (2020) Detection From Göktürk-2 Satellite Images Using Convolutional Neural Network. *Icatces 2020 Proceeding Book*, 45.
- Aghighi, H., Azadbakht, M., Ashourloo, D., Shahrabi, H. S., & Radiom, S. (2018). Machine Learning Regression Techniques For The Silage Maize Yield Prediction Using Time-Series Images Of Landsat 8 Oli. *Ieee Journal Of Selected Topics In Applied Earth Observations And Remote Sensing*, 11(12), 4563-4577.
- Ahmadian, N., Ghasemi, S., Wigneron, J. P., & Zölitz, R. (2016). Comprehensive Study Of The Biophysical Parameters Of Agricultural Crops Based On Assessing Landsat 8 Oli And Landsat 7 Etm+ Vegetation Indices. *Giscience & Remote Sensing*, 53(3), 337-359
- Akar, Ö., & Tunç Görmüş E. (2019). Göktürk-2 Ve Hyperion Eo-1 Uydu Görüntülerinden Rastgele Orman Sınıflandırıcısı Ve Destek Vektör Makineleri Ile Arazi Kullanım Haritalarının Üretilmesi. *Geomatik*, 4(1), 68-81.
- Alhawiti, R. H., & Mitsova, D. (2016). Using Landsat-8 Data To Explore The Correlation Between Urban Heat Island And Urban Land Uses. *Ijret: International Journal Of Research In Engineering And Technology*, 5(3), 457-466.
- Altun, M., & Türker, M. (2021). Çoklu Zamanlı Sentinel-2 Görüntülerinden Tarımsal Ürün Tespiti: Mardin-Kızıltepe Örneği. *Afyon Kocatepe Üniversitesi Fen Ve Mühendislik Bilimleri Dergisi*, 21(4), 881-899.
- Apaydın, C., & Abdikan, S. (2021). Fındık Bahçelerinin Sentinel-2 Verileri Kullanılarak Piksel Tabanlı Sınıflandırma Yöntemleriyle Belirlenmesi. *Geomatik*, 6(2), 107-114.
- Armanto, A. N., Dasanto, B. D., & Hidayati, R. (2021). Forest Fires And Carbon Emission Release In Semi-Arid Regions Of Indonesia: The Evidence From Medium Resolution Of Satellite Imagery. In *Iop Conference Series: Earth And Environmental Science* (Vol. 622, No. 1, P. 012021). Iop Publishing.
- Atak, V. O., Erdoğan, M., & Yılmaz, A. (2015). Göktürk-2 Uydu Görüntü Testleri. *Harita Dergisi*, 81(2), 18-33.

Baatz, M. (2000). Multi Resolution Segmentation: An Optimum Approach For High Quality Multi Scale Image Segmentation. In Beutrage Zum Agit-Symposium. Salzburg, Heidelberg, 2000 (Pp. 12-23).

Bağdatlı, A., Ok, A., Özdarici Ok, A. S. L. I., Erdoğan, O., Albut, S., & Oğuz, H. (2016) Görüntü Sınıflandırması Yoluyla Göktürk 2 Görüntüsünden Tarımsal Ürün Deseninin Belirlenmesi Nevşehir Sarıhıdır Köyü Kızılırmak Sağ Sahil Bandı Tarım Arazileri Pilot Uygulaması. Uzaktan Algılama-Cbs Sempozyumu (Uzal-Cbs 2016), 5, Adana

Bai, T., Zhang, N., Mercatoris, B., & Chen, Y. (2019). Jujube Yield Prediction Method Combining Landsat 8 Vegetation Index And The Phenological Length. Computers And Electronics In Agriculture, 162, 1011-1027.

Bala, R., Prasad, R., & Yadav, V. P. (2020). Thermal Sharpening Of Modis Land Surface Temperature Using Statistical Downscaling Technique In Urban Areas. Theoretical And Applied Climatology, 141(3), 935-946.

Barrett, E. C. (2013). Introduction To Environmental Remote Sensing. Routledge.

Batur, E., & Maktav, D. (2018). Assessment Of Surface Water Quality By Using Satellite Images Fusion Based On Pca Method In The Lake Gala, Turkey. Ieee Transactions On Geoscience And Remote Sensing, 57(5), 2983-2989.

Bayram, B., Erdem, F., Akpınar, B., Ince, A., Bozkurt, S., Reis, H., & Şeker, D. (2017). The Efficiency Of Random Forest Method For Shoreline Extraction From Landsat-8 And Gokturk-2 Imageries. 4th International Workshop On Geoinformation Science, 141-145

Belgiu, M., & Csillik, O. (2018). Sentinel-2 Cropland Mapping Using Pixel-Based And Object-Based Time-Weighted Dynamic Time Warping Analysis. Remote Sensing Of Environment, 204, 509-523.

Bilgilioğlu, B. B. (2015). Uzaktan Algılanmış Görüntülerden Faydalanılarak Obje-Tabanlı Sınıflandırma Yöntemi İle Kent Merkezlerindeki Detayların Çıkarımı (Master's Thesis, Aksaray Üniversitesi Fen Bilimleri Enstitüsü).

Blaschke, T., Hay, G. J., Kelly, M., Lang, S., Hofmann, P., Addink, E., ... & Tiede, D. (2014). Geographic Object-Based Image Analysis-Towards A New Paradigm. Isprs Journal Of Photogrammetry And Remote Sensing, 87, 180-191.

Bostancı, L. G. Y., & Genç, L. (2007). Troia Milli Parkı Arazi Kullanım Ve Bitki Örtüsü Değişiminin Uzaktan Algılama Ve Coğrafi Bilgi Sistemi Yardımıyla Belirlenmesi. Tekirdağ Ziraat Fakültesi Dergisi, 4(1), 27-41.

Burnett C, Blaschke T, 2003, A Multi-Scale Segmentation / Object Relationship Modelling Methodology For Landscape Analysis, Ecological Modelling, 168, 233- 249

Campbell, J. B. (1983). Mapping The Land: Aerial Imagery For Land Use Information. Resource Publications In Geography. Association Of American Geographers, 1710 Sixteenth Street, Nw, Washington, Dc 20009.

Charrua, A. B., Padmanaban, R., Cabral, P., Bandeira, S., & Romeiras, M. M. (2021). Impacts Of The Tropical Cyclone Idai In Mozambique: A Multi-Temporal Landsat Satellite Imagery Analysis. Remote Sensing, 13(2), 201.

Chen, P., & Jing, Q. (2017). A Comparison Of Two Adaptive Multivariate Analysis Methods (Plsr And Ann) For Winter Wheat Yield Forecasting Using Landsat-8 Oli Images. Advances In Space Research, 59(4), 987-995.

Chen, W., Peng, J., Hong, H., Shahabi, H., Pradhan, B., Liu, J., ... & Duan, Z. (2018). Landslide Susceptibility Modelling Using Gis-Based Machine Learning Techniques For Chongren County, Jiangxi Province, China. Science Of The Total Environment, 626, 1121-1135.

Chen, W., Pourghasemi, H. R., Panahi, M., Kornejady, A., Wang, J., Xie, X., & Cao, S. (2017). Spatial Prediction Of Landslide Susceptibility Using An Adaptive Neuro-Fuzzy Inference System Combined With Frequency Ratio, Generalized Additive Model, And Support Vector Machine Techniques. Geomorphology, 297, 69-85.

Chi, M. M., Feng, R. Ve Bruzzone, L. (2008). Classification Of Hyperspectral Remote-Sensing Data With Primal Svm For Small-Sized Training Dataset Problem. Advances In Space Research, 41, 1793-1799.

Chuvieco, E. (2016). Fundamentals Of Satellite Remote Sensing: An Environmental Approach. Crc Press.

Çoban, H. (2016). Türkiye'nin Yer Gözlem Uydu Sistemleri Ve Ormancılık Uygulamalarında Kullanılabilirliği. Turkish Journal Of Forestry, 17(1), 99-107.

Çölkesen İ. 2015. Yüksek Çözünürlüklü Uydu Görüntüleri Kullanarak Benzer Spektral Özelliklere Sahip Doğal Nesnelerin Ayırt Edilmesine Yönelik Bir Metodoloji Geliştirme , Doktora Tezi,İstanbul Teknik Üniversitesi ,Türkiye.

Çölkesen, İ. (2009). Uzaktan Algılamada İleri Sınıflandırma Tekniklerinin Karşılaştırılması Ve Analizi, Y. Lisans Tezi,Gebze Yüksek Teknoloji Entitüsü, Türkiye.

Çölkesen, İ., Sesli, F. A., & Akyol, N. (2007). Avrupa Birliği'ne Uyum Sürecinde Türkiye'deki Arsa Ve Arazi Düzenlemesi Uygulamaları. *HKMO 11. Türkiye Harita Bilimsel ve Teknik Kurultayı*.

Congalton, R. G., Gu, J., Yadav, K., Thenkabail, P., & Ozdogan, M. (2014). Global land cover mapping: A review and uncertainty analysis. *Remote Sensing*, 6(12), 12070-12093.

Crone, G. R., Alaminos, L., & Hernández Campos, J. (1956). Historia de los mapas. Breviarios del fondo de Cultura Económica;.

De Castro Padilha, M. C., Vicente, L. E., Demattê, J. A., Loebmann, D. G. D. S. W., Vicente, A. K., Salazar, D. F., & Guimarães, C. C. B. (2020). Using Landsat And Soil Clay Content To Map Soil Organic Carbon Of Oxisols And Ultisols Near São Paulo, Brazil. *Geoderma Regional*, 21, E00253.

De Mattos Scaramuzza, C. A., Sano, E. E., Adami, M., Bolfe, E. L., Coutinho, A. C., Esquerdo, J. C. D. M., & Gustavo, B. S. (2017). Land-Use And Land-Cover Mapping Of The Brazilian Cerrado Based Mainly On Landsat-8 Satellite Images. *Revista Brasileira De Cartografia*, 69(6).

Demers, A. M., Banks, S. N., Pasher, J., Duffe, J., & Laforest, S. (2015). A comparative analysis of object-based and piksel-based classification of RADARSAT-2 C-bant and optical satellite data for mapping shoreline types in the Canadian arctic. *Canadian Journal of Remote Sensing*, 41(1), 1-19.

Demirpolat, C., & Leloğlu, U. M. (2018, May). Barley Yield Estimation With Sentinel-2 Vegetation Indices. In 2018 26th Signal Processing And Communications Applications Conference (Siu) (Pp. 1-4). Ieee.

Dizdaroğlu, T. (2019). Sentinel-1 Ve Sentinel-2 Verilerinden Tarımsal Ürün Sınıflandırması İçin Makine Öğrenme Algoritmalarının Karşılaştırılması (Master's Thesis, Fen Bilimleri Enstitüsü).

Durmazbilek Ş. (2021). Land cover classification using cloud-based machine learning techniques: A case study from Istanbul Metropolitan City, Yüksek Lisans, İstanbul Teknik Üniversitesi, Türkiye.

eCognition User Book, https://docs.ecognition.com/v9.5.0/eCognition_documentation.htm [Erişim Tarihi 06 Nisan 2021]

Ed Chaves, M., Ca Picoli, M., & D Sanches, I. (2020). Recent Applications Of Landsat 8/Oli And Sentinel-2/Msi For Land Use And Land Cover Mapping: A Systematic Review. *Remote Sensing*, 12(18), 3062. *Ensing & Spatial Information Sciences*, 41.

Emery, B., & Camps, A. (2017). Introduction to satellite remote sensing: atmosphere, ocean, land and cryosphere applications. Elsevier.

- Fieuzal, R., Bustillo, V., Collado, D., & Dedieu, G. (2020). Combined Use Of Multi-Temporal Landsat-8 And Sentinel-2 Images For Wheat Yield Estimates At The Intra-Plot Spatial Scale. *Agronomy*, 10(3), 327.
- Foody, G. M., Mathur, A., Sanchez-Hernandez, C. Ve Boyd, D. S. (2006). Training Set Size Requirements For The Classification Of A Specific Class. *Remote Sensing Of Environment*, 104, 1-14.
- Forkuor, G., Dimobe, K., Serme, I., & Tondoh, J. E. (2018). Landsat-8 Vs. Sentinel-2: Examining The Added Value Of Sentinel-2's Red-Edge Bands To Land-Use And Land-Cover Mapping In Burkina Faso. *Giscience & Remote Sensing*, 55(3), 331-354.
- Fuller, R. M., Groom, G. B., & Jones, A. R. (1994). The land-cover map of great Britain: an automated classification of landsat thematic mapper data. *Photogrammetric Engineering and Remote Sensing*, 60(5), 553-562.
- Gao, Q., Zribi, M., Escorihuela, M. J., & Baghdadi, N. (2017). Synergetic Use Of Sentinel-1 And Sentinel-2 Data For Soil Moisture Mapping At 100 M Resolution. *Sensors*, 17(9), 1966
- García-Mora, T. J., Mas, J. F., & Hinkley, E. A. (2012). Land cover mapping applications with MODIS: a literature review. *International Journal of Digital Earth*, 5(1), 63-87.
- Gazel E, Seyfeli S, Kocaman S, Gruen A, Troyer M (2018) Gokturk-2 Ve Pleiades Goruntulerinin Kalitesinin Incelenmesi. *Uzalcbs Conference*, 18–21 September, Eskisehir, Turkey (Accepted For Publication)
- Genç, L., Saçan, M., Turhan, H., & Asar, B. (2010). Arazi Örtüsünün Landsat Tm Uydu Görüntüleri Yardımıyla Belirlenmesi
- Power, C. H., & Gibson, P. J. (2000). *Introductory remote sensing: digital image processing and applications*.
- Göksel, Ç., Balçık, F. B., Keskin, M., & Çelik, B. (2016) *Uzaktan Algılama Teknolojisi Ile Arazi Kullanımı Değişiminin Belirlenmesi; Mersin İl Bütünü Ve Akdeniz İlçesi Örneği*
- Gómez, C., White, J. C., & Wulder, M. A. (2016). Optical Remotely Sensed Time Series Data For Land Cover Classification: A Review. *Isprs Journal Of Photogrammetry And Remote Sensing*, 116, 55-72.
- Grekousis, G., Mountrakis, G., & Kavouras, M. (2015). An overview of 21 global and 43 regional land-cover mapping products. *International Journal of Remote Sensing*, 36(21), 5309-5335.

Günlü, A., & Gögerçin, R. (2017) Çakü Orman Fakültesi Araştırma Ormanında Göktürk-2 Uydu Görüntüsü Kullanılarak Bazı Meşcere Parametrelerinin Tahmin Edilmesi. Anadolu Orman Araştırmaları Dergisi, 3(1), 1-13.

Gürcan, İ., Teke, M., & Leloğlu, U. M. (2016, May). Land Use/Land Cover Classification For Göktürk-2 Satellite. In 2016 24th Signal Processing And Communication Application Conference (Siu) (Pp. 2097-2100). Ieee

Gürgenburan G., ve Çınar, E. (2015). Göktürk-2: Two years of operation. 7th International Conference on Recent Advances in Space Technologies (RAST), İstanbul. doi: <https://doi.org/10.1109/RAST.2015.7208378>

Hakan, O. Ğ. U. Z. (2016). LST Calculator: A Python Tool for Retrieving Land Surface Temperature from Landsat 8 Imagery. Environmental Sustainability and Landscape Management, 560.

Hill, M. J. (2013). Vegetation Index Suites As Indicators Of Vegetation State In Grassland And Savanna: An Analysis With Simulated Sentinel 2 Data For A North American Transect. Remote Sensing Of Environment, 137, 94-111.

Hoffman R, Jain, A K, (1987), Segmentation And Classification Of Range Images, Ieee Trans, Pattern Anal, Machine Intell, 9, 608–620.

Hu, G. Y., Dong, Z. B., Wei, Z. H. Ve Lu, J. F. (2010). Land Use And Land Cover Change Monitoring In The Zoige Wetland By Remote Sensing. Sixth International Symposium On Digital Earth: Data Processing And Applications, 7841,710.

Huang, J., Tian, L., Liang, S., Ma, H., Becker-Reshef, I., Huang, Y., ... & Wu, W. (2015). Improving Winter Wheat Yield Estimation By Assimilation Of The Leaf Area Index From Landsat Tm And Modis Data Into The Wofost Model. Agricultural And Forest Meteorology, 204, 106-121

İnternet Adresi : http://nik.com.tr/content_sistem_uydu.asp?id=102 [Erişim 12 Mart 2021].

İnternet Adresi : http://www.nik.com.tr/content_sistem_uydu.asp?id=34 [Erişim 14 Mart 2021].

İnternet Adresi : <https://www.datacamp.com/tutorial/k-nearest-neighbor-classification-scikit-learn> [Erişim 03 Mart 2021].

İnternet Adresi : <https://www.usgs.gov/landsat-missions/landsat-8> [Erişim 15 Mart 2021].

İrfanoğlu, F., & Balçık, F. B. (2018) Arazi Örtüsü Ve Arazi Kullanımı Sınıflarının Sentinel-2 Görüntüsü Ve Nesne Tabanlı Sınıflandırma Yöntemiyle Belirlenmesi. Vii. Uzaktan Algılama-Cbs Sempozyumu (Uzal-Cbs 2018), Eskişehir, Türkiye

Jensen, J. R. (2009). Remote Sensing Of The Environment: An Earth Resource Perspective 2/E. Pearson Education India

Jia, K., Wei, X., Gu, X., Yao, Y., Xie, X., & Li, B. (2014). Land Cover Classification Using Landsat 8 Operational Land Imager Data In Beijing, China. Geocarto International, 29(8), 941-951.

Kalkan K, Maktav D, (2010) Nesne Tabanlı Ve Piksel Tabanlı Sınıflandırma Yöntemlerinin Karşılaştırılması (İkonos Örneği), Iı. Uzaktan Algılama Ve Coğrafi Bilgi Sistemleri Sempozyumu, 11 – 13, Gebze – Kocaeli

Kalkan, K., Filiz, Bg, Özer, O., & Teke, M. (2015, Haziran). Göktürk-2 Görüntülerinden Bitki Ayrım Analizi. 2015 Yılında 7. Uluslararası Uzay Teknolojilerindeki Son Gelişmeler Konferansı (Rast) (S. 329-332). Ieee.

Karakizi, C., Karantza, K., Vakalopoulou, M., & Antoniou, G. (2018). Detailed Land Cover Mapping From Multitemporal Landsat-8 Data Of Different Cloud Cover. Remote Sensing, 10(8), 1214.

Kaya Y. (2020). Çok bantlı uydu görüntüleri kullanılarak buğday bitkisinin incelenmesi – Ceylanpınar TİGEM örneği , Yüksek Lisans Tezi , Çok bantlı uydu görüntüleri kullanılarak buğday bitkisinin incelenmesi – Ceylanpınar TİGEM örneği , Harran Üniversitesi , Türkiye.

Kaya, N. S., Turan, İ. D., Dengiz, O., & Saygin, F. (2020). Farklı Konumsal Çözünürlüğe Sahip Uydu Görüntüleri Kullanarak Corine Arazi Örtüsü/Arazi Kullanım Sınıflarının Belirlenmesi. Türkiye Tarımsal Araştırmalar Dergisi, 7(2), 207-218.

Kaya, Y. Ve Polat, N.(2021) . Uydu Görüntüleriyle Buğday Bitkisinin İncelenmesi.

Kaya, Y., & Polat, N. (2019). Bitki İndeksi Kullanarak Buğday Bitkisinin Fenolojik Evrelerinin İncelenmesi. Türkiye Ulusal Fotogrametri Ve Uzaktan Algılama Birliği Vii. Teknik Sempozyumu (Tufuab'2019), 25-27.

Kaynarca, M. Ve Demir, N. (2018). Multispektral Göktürk-2 Ve Sentinel 1a Sentetik Açıklıklı Radar Görüntüleri Kullanılarak Kent Yapılarının Tespiti. Multidisipliner Dijital Yayıncılık Enstitüsü Bildirileri , 2 (7), 360.

Khan, M. S., Semwal, M., Sharma, A., & Verma, R. K. (2020). An Artificial Neural Network Model For Estimating Mentha Crop Biomass Yield Using Landsat 8 Oli. Precision Agriculture, 21(1), 18-33.

Kocaman S, Ural S, Karakas G, Bakici S (2017) 3d Processing Of Gokturk 2 Imagery. In: Proceedings Of 38th Asian Conference On Remote Sensing, New Delhi, India

Kuc, G., & Chormański, J. (2019). Sentinel-2 Imagery For Mapping And Monitoring Imperviousness In Urban Areas. International Archives Of The Photogrammetry, Remote Sensing And Spatial Information Sciences, 42(1/W2).

Kumar, M. S., Kolluru, V., Gowthami, S. B., Anjita, N. A., Nayana, N., Regi, L., & Dwarkish, G. S. (2021). Monitoring Land Use And Land Cover Changes In Coastal Karnataka. Trends In Civil Engineering And Challenges For Sustainability, 785-795.

Kunwar, P., Kachhwaha, T. S., Kumar, A., Agrawal, A. K., Singh, A. N. Ve Mendiratta, N. (2010). Use Of High-Resolution Ikonos Data And Gis Technique For Transformation Of Landuse/Landcover For Sustainable Development. Current Science, 98, 204-212.

Küpcü R. (2015). “RASAT ve Göktürk-2 Uydu Görüntülerinin Uzaktan Algılama Yazılımları İle Farklı Referans Verileri Kullanılarak Geometrik Düzeltme Doğruluğunun Araştırılması, Yüksek Lisans Tezi, Anadolu Üniversitesi, Türkiye.

Kuruca, M. , Matci, D. K. & Avdan, U. (2021). The Potential Of Gokturk 2 Satellite Images For Mapping Burnt Forest Areas . Turkish Journal Of Agriculture And Forestry , 45 (1) , 91-101 . Retrieved From <https://Dergipark.Org.Tr/En/Pub/Tbtkagriculture/Issue/62410/941420>

Lemus-Canovas, M., Martin-Vide, J., Moreno-Garcia, M. C., & Lopez-Bustins, J. A. (2020). Estimating Barcelona's Metropolitan Daytime Hot And Cold Poles Using Landsat-8 Land Surface Temperature. Science Of The Total Environment, 699, 134307.

Li, P., Jiang, L., & Feng, Z. (2014). Cross-Comparison Of Vegetation Indices Derived From Landsat-7 Enhanced Thematic Mapper Plus (Etm+) And Landsat-8 Operational Land Imager (Oli) Sensors. Remote Sensing, 6(1), 310-329.

Liao, C., Wang, J., Dong, T., Shang, J., Liu, J., & Song, Y. (2019). Using Spatio-Temporal Fusion Of Landsat-8 And Modis Data To Derive Phenology, Biomass And Yield Estimates For Corn And Soybean. Science Of The Total Environment, 650, 1707-1721

Lillesand, T.M., Kiefer, R.W. Ve Chipman, J.W. (2007). Remote Sensing And Image Interpretation. 6th Edition, John Wiley & Sons., New York, Usa

Lin, Y. H., Chang, L. R., Lee, Y. H., Tseng, H. W., Kuo, T. B., & Chen, S. H. (2014). Development And Validation Of The Smartphone Addiction Inventory (Spai). Plos One, 9(6), E98312.

- Liu, H., Meng, L., Zhang, X., Susan, U., Ning, D., & Sun, S. (2015). Estimation Model Of Cotton Yield With Time Series Landsat Images. *Transactions Of The Chinese Society Of Agricultural Engineering*, 31(17), 215-220.
- Liu, X., Zhu, W. Q., Yang, X. Q. Ve Pan, Y. Z. (2006). Modeling Of Population Density Based On Gis And Rs. 2006 Ieee International Geoscience And Remote Sensing Symposium, Vols 1-8, 1431-1434.
- Longley, P. A., Goodchild, M. F., Maguire, D. J., & Rhind, D. W. (2005). *Geographic Information Systems And Science*. John Wiley & Sons.
- Loveland, T. R., & Giri, C. P. (2012). History of land-cover mapping. *Remote sensing of land use and land cover*. CRC Press, Boca Raton, USA. [http://dx. doi. org/http://dx. doi. org/10.1201/b11964-4](http://dx.doi.org/http://dx.doi.org/10.1201/b11964-4), 13-22.
- Lu, D., & Weng, Q. (2007). A survey of image classification methods and techniques for improving classification performance. *International journal of Remote sensing*, 28(5), 823-870.
- Madugundu, R., Al-Gaadi, K. A., Tola, E., Hassaballa, A. A., & Kayad, A. G. (2018). Utilization Of Landsat-8 Data For The Estimation Of Carrot And Maize Crop Water Footprint Under The Arid Climate Of Saudi Arabia. *Plos One*, 13(2), E0192830.
- Mathan, M., & Krishnaveni, M. (2020). Monitoring Spatio-Temporal Dynamics Of Urban And Peri-Urban Land Transitions Using Ensemble Of Remote Sensing Spectral Indices—A Case Study Of Chennai Metropolitan Area, India. *Environmental Monitoring And Assessment*, 192(1), 15.
- Mather, P.M. Ve Koch, M. (2011). *Computer Processing Of Remotely-Sensed Images: An Introduction*. Fourth Edition. Wiley-Blackwell, Chichester, Uk
- Milewski, R., Chabrillat, S., & Bookhagen, B. (2020). Analyses Of Namibian Seasonal Salt Pan Crust Dynamics And Climatic Drivers Using Landsat 8 Time-Series And Ground Data. *Remote Sensing*, 12(3), 474.
- Mishra, V. K., & Pant, T. (2020, February). Mapping And Prediction Of Urban Area With Markov-Ca Model Using Landsat-8 Images For Effective Management Of Urban Area In Prayagraj City. In 2020 Ursi Regional Conference On Radio Science (Ursi-Rcrs) (Pp. 1-5). Ieee.
- Mohamed, E. S., Baroudy, A., El-Beshbeshy, T., Emam, M., Belal, A. A., Elfadaly, A., ... & Lasaponara, R. (2020). Vis-Nir Spectroscopy And Satellite Landsat-8 Oli Data To Map Soil Nutrients In Arid Conditions: A Case Study Of The Northwest Coast Of Egypt. *Remote Sensing*, 12(22), 3716.

Mohammadpoor, M., & Eshghizadeh, M. (2021). Introducing An Intelligent Algorithm For Extraction Of Sand Dunes From Landsat Satellite Imagery In Terrestrial And Coastal Environments. *Journal Of Coastal Conservation*, 25(1), 1-12.

Morgan, B. E., Chipman, J. W., Bolger, D. T., & Dietrich, J. T. (2021). Spatiotemporal Analysis Of Vegetation Cover Change In A Large Ephemeral River: Multi-Sensor Fusion Of Unmanned Aerial Vehicle (Uav) And Landsat Imagery. *Remote Sensing*, 13(1), 51.

Murthy, C. S., Raju, P. V., & Badrinath, K. V. S. (2003). Classification Of Wheat Crop With Multi-Temporal Images: Performance Of Maximum Likelihood And Artificial Neural Networks. *International Journal Of Remote Sensing*, 24(23), 4871-4890.

Musaoğlu N. (1999). Elektro-optik ve mikrodalga algılayıcılardan elde edilen uydu verilerinden orman alanlarında meşcere tiplerinin ve yetiştirme ortamı birimlerinin belirlenme olanakları, Tez (Doktora) -- İstanbul Teknik Üniversitesi, İstanbul, Türkiye.

Mutluoğlu Ö, Yakar M Ve Yılmaz H M (2013) Worldview-2 (50 Cm) Uydu Görüntüsünün Konumsal Doğruluğunun Araştırılması. *Bilim Ve Teknoloji Dergisi*, 4(4) 321-329.

Nguyen, K. A., Liou, Y. A., Tran, H. P., Hoang, P. P., & Nguyen, T. H. (2020). Soil Salinity Assessment By Using Near-Infrared Channel And Vegetation Soil Salinity Index Derived From Landsat 8 Oli Data: A Case Study In The Tra Vinh Province, Mekong Delta, Vietnam. *Progress In Earth And Planetary Science*, 7(1), 1-16.

Nuarsa, I. W., Nishio, F., & Hongo, C. (2012). Rice Yield Estimation Using Landsat Etm+ Data and Field Observation. *Journal Of Agricultural Science*, 4(3), 45.

Orhan O, Bilgilioglu Ss, Kaya Z, Ozcan Ak, Bilgilioglu H (2020) Assessing And Mapping Landslide Susceptibility Using Different Machine Learning Methods. *Geocarto International* 1–26

Ouyang, L., Mao, D., Wang, Z., Li, H., Man, W., Jia, M., ... & Liu, H. (2017). Analysis Crops Planting Structure and Yield Based On Gf-1 And Landsat8 Oli Images. *Transactions Of The Chinese Society Of Agricultural Engineering*, 33(11), 147-156.

Özcan, A., & Aytaş, İ. (2019). Biyoçeşitlilik Sıcak Noktası Ve Jeolojik Miras Alanı Olan Karstik Peyzajların Zamansal Değişimi: Çankırı Jipsli Tepeleri. *Yüzüncü Yıl University Journal of Agricultural Sciences*, 29(4), 618-627.

Pekkan, Ö. I., Kalkan, K., & Çabuk, A. (2020) Arazi Örtüsü Değişiminin Modellenmesi: Karaburun Yarımadası Örneği. *Gsi Journals Serie C: Advancements In Information Sciences And Technologies*, 3(2), 21-38.

Pu, D. C., Sun, J. Y., Ding, Q., Zheng, Q., Li, T. T., & Niu, X. F. (2020). Mapping Urban Areas Using Dense Time Series Of Landsat Images And Google Earth Engine. *The International Archives Of Photogrammetry, Remote Sensing And Spatial Information Sciences*, 42, 403-409.

Qiu, C., Mou, L., Schmitt, M., & Zhu, X. X. (2019). Local Climate Zone-Based Urban Land Cover Classification From Multi-Seasonal Sentinel-2 Images With A Recurrent Residual Network. *Isprs Journal Of Photogrammetry And Remote Sensing*, 154, 151-162.

Rakhmonov, S., Umurzakov, U., Rakhmonov, K., Bozarov, I., & Karamatov, O. (2021, January). Land Use And Land Cover Change In Khorezm, Uzbekistan. In *E3s Web Of Conferences* (Vol. 227, P. 01002). Edp Sciences.

Richards, J. A. (1999). *Remote Sensing Digital Image Analysis* (Vol. 3). Berlin Et Al.: Springer.

Richter, R., Hutengs, C., Wirth, C., Bannehr, L., & Vohland, M. (2021). Detecting Tree Species Effects On Forest Canopy Temperatures With Thermal Remote Sensing: The Role Of Spatial Resolution. *Remote Sensing*, 13(1), 135.

Rochel X, Abadie J, Avon C, et al (2017) Quelles sources cartographiques pour la définition des usages anciens du sol en France. *Rev For Française*:353.<https://doi.org/10.4267/2042/67866>

Rokade, V. M., Kundal, P. Ve Joshi, A. K. (2007). Groundwater Potential Modelling Through Remote Sensing And Gis: A Case Study From Rajura Taluka, Chandrapur District, Maharashtra. *Journal Of The Geological Society Of India*, 69, 943-948.

Roy, D. P., Wulder, M. A., Loveland, T. R., Woodcock, C. E., Allen, R. G., Anderson, M. C., ... & Zhu, Z. (2014). Landsat-8: Science And Product Vision For Terrestrial Global Change Research. *Remote Sensing Of Environment*, 145, 154-172.

Sabins Jr, F. F. (1986). *Remote sensing: principles and interpretation*. Chevron Oil Field Research Co..

Sakarya U, Demirhan Ih, Deveci S, Teke M, Demirkesen C, Kupcu R, Oztoprak F, Efendioglu M, Simsek Fe, Gurbuz Zs (2016) Absolute Radiometric Calibration Of The Gokturk-2 Satellite Sensor Using Tuz Golu (Landnet Site) From Ndvi Perspective, *Isprs—International Archives Of The Photogrammetry, Remote Sensing And Spatial Information Sciences*, Volume Xli-B1, P 373–377

Sánchez-Espinosa, A., & Schröder, C. (2019). Land Use And Land Cover Mapping In Wetlands One Step Closer To The Ground: Sentinel-2 Versus Landsat 8. *Journal Of Environmental Management*, 247, 484-498.

Sarp, G., Temurçin, K., Aldirmaz, Y., & Baydoğan, E. (2018). Göktürk-2 Uydu Görüntülerinden Kentsel Alan Tespitinin Doğruluğunun Test Edilmesi. *Www. Küre. Kuruluş*

Sekertekin, A., Marangoz, A. M., & Akcin, H. (2017). Pikel-Based Classification Analysis Of Land Use Land Cover Using Sentinel-2 And Landsat-8 Data. *International Archives Of The Photogrammetry, Remote Sensing & Spatial Information Sciences*, 42.

Semmens, K. A., Anderson, M. C., Kustas, W. P., Gao, F., Alfieri, J. G., Mckee, L., ... & Vélez, M. (2016). Monitoring Daily Evapotranspiration Over Two California Vineyards Using Landsat 8 In A Multi-Sensor Data Fusion Approach. *Remote Sensing Of Environment*, 185, 155-170.

Sentinel-2 User Handbook. (2015). ESA Standard Document, Issue 1, Rev 2, European Space Agency. Retrieved from Erişim adresi: https://sentinels.copernicus.eu/web/sentinel/user-guides/document-library//asset_publisher/xlslt4309D5h/content/sentinel-2-user-handbook.

Sertel, E., & Akay, S. S. (2015). High Resolution Mapping Of Urban Areas Using Spot-5 Images And Ancillary Data. *International Journal Of Environment And Geoinformatics*, 2(2), 63-76.

Silvero, N. E. Q., Demattê, J. A. M., Amorim, M. T. A., Dos Santos, N. V., Rizzo, R., Safanelli, J. L., ... & Bonfatti, B. R. (2021). Soil Variability And Quantification Based On Sentinel-2 And Landsat-8 Bare Soil Images: A Comparison. *Remote Sensing Of Environment*, 252, 112117.

Skakun, S., Franch, B., Vermote, E., Roger, J. C., Justice, C., Masek, J., & Murphy, E. (2018, July). Winter Wheat Yield Assessment Using Landsat 8 And Sentinel-2 Data. In *Igarss 2018-2018 Ieee International Geoscience And Remote Sensing Symposium* (Pp. 5964-5967). Ieee.

Skakun, S., Vermote, E., Franch, B., Roger, J. C., Kussul, N., Ju, J., & Masek, J. (2019). Winter Wheat Yield Assessment From Landsat 8 And Sentinel-2 Data: Incorporating Surface Reflectance, Through Phenological Fitting, Into Regression Yield Models. *Remote Sensing*, 11(15), 1768.

Skakun, S., Vermote, E., Roger, J. C., & Franch, B. (2017). Combined Use Of Landsat-8 And Sentinel-2a Images For Winter Crop Mapping And Winter Wheat Yield Assessment At Regional Scale. *Aims Geosciences*, 3(2), 163.

Sofu, A. M., İmamoglu, M., Kahraman, F., Çetin, G. B., & Aptoula, E. (2020, October). Fine-Grained Urban Land Use And Land Cover Classification Through Multi-Temporal And Multispectral Remote

Sensing Images. In 2020 28th Signal Processing And Communications Applications Conference (Siu) (Pp. 1-4). Ieee.

Sokolova, M., & Lapalme, G. (2009). A Systematic Analysis Of Performance Measures For Classification Tasks. *Information Processing & Management*, 45(4), 427-437.

Sönmez, N., & Sari M.,(2016). Uzaktan Algılama Temel Prensipleri Ve Uygulama Alanlari. *Derim*, 19(2), 16-30.

Sonobe, R., Yamaya, Y., Tani, H., Wang, X., Kobayashi, N., & Mochizuki, K. I. (2017). Assessing The Suitability Of Data From Sentinel-1a And 2a For Crop Classification. *Giscience & Remote Sensing*, 54(6), 918-938.

Stromann, O., Nascetti, A., Yousif, O., & Ban, Y. (2020). Dimensionality Reduction And Feature Selection For Object-Based Land Cover Classification Based On Sentinel-1 And Sentinel-2 Time Series Using Google Earth Engine. *Remote Sensing*, 12(1), 76.

Sutariya, S., Hirapara, A., Meherbanali, M., Tiwari, M., Singh, V., & Kalubarme, M. (2021). Soil Moisture Estimation Using Sentinel-1 Sar Data And Land Surface Temperature In Panchmahal District, Gujarat State. *International Journal Of Environment And Geoinformatics*, 8(1), 65-77.

Teke, M. (2016). Satellite Image Processing Workflow For Rasat And Göktürk-2. *Journal Of Aeronautics And Space Technologies*, 9(1), 1-13.

Teke, M., & Yardımcı, Y. (2016, May). Crop Classification With Göktürk-2 Time Series Imagery. In 2016 24th Signal Processing And Communication Application Conference (Siu) (Pp. 1553-1556). Ieee.

Thanh Noi, P., & Kappas, M. (2018). Comparison Of Random Forest, K-Nearest Neighbor, And Support Vector Machine Classifiers For Land Cover Classification Using Sentinel-2 Imagery. *Sensors*, 18(1), 18

Thomas, V. A., Wynne, R. H., Kauffman, J., Mccurdy, W., Brooks, E. B., Thomas, R. Q., & Rakestraw, J. (2021). Mapping Thins To Identify Active Forest Management In Southern Pine Plantations Using Landsat Time Series Stacks. *Remote Sensing Of Environment*, 252, 112127.

Topan, H., Çam, A., Oruç, M., & Teke, M. (2016). Göktürk-2 Görüntülerinin Geometrik Ve Radyometrik Açından Değerlendirilmesi. *Uzaktan Algılama Ve Coğrafi Bilgi Sistemleri Sempozyumu*, 5-7.

Turan, İ. D., Dengiz, O., & Kaya, N. S. (2021). Arazi Örtüsü/Arazi Kullanım Değişimlerinin Farklı Zamanlı Landsat Uydu Görüntüleri İle Belirlenmesi: Çarşamba Delta Ovası Örneği. Çomü Ziraat Fakültesi Dergisi, 9(1), 141-152.

Wang, J., Huang, J. F., Wang, X. Z., Jin, M. T., Zhou, Z., Guo, Q. Y., ... & Song, X. D. (2015). Estimation Of Rice Phenology Date Using Integrated HJ-1 Ccd And Landsat-8 Oli Vegetation Indices Time-Series Images. Journal Of Zhejiang University-Science B, 16(10), 832-844.

Weigand, M., Staab, J., Wurm, M., & Taubenböck, H. (2020). Spatial And Semantic Effects Of Lucas Samples On Fully Automated Land Use/Land Cover Classification In High-Resolution Sentinel-2 Data. International Journal Of Applied Earth Observation And Geoinformation, 88, 102065.

Wu, X., Liu, L. S., Zhang, Y. L., & Paudel, B. (2021). Land Use And Land Cover Change Within The Koshi River Basin Of The Central Himalayas Since 1990. Journal Of Mountain Science, 18(1), 159-177.

Wu, Z., Middleton, B., Hetzler, R., Vogel, J., & Dye, D. (2015). Vegetation Burn Severity Mapping Using Landsat-8 And Worldview-2. Photogrammetric Engineering & Remote Sensing, 81(2), 143-154.

Yang, X. ve Lo, C. P., (2000) Relative radiometric normalization performance for change detection from multi-date satellite images, Photogrammetric Engineering and Remote Sensing, 66, 967-980.

Yang, X., & Li, J. (Eds.). (2012). Advances in mapping from remote sensor imagery: techniques and applications. CRC Press.

Yang, H., Zhang, X., Xu, M., Shao, S., Wang, X., Liu, W., ... & Liu, H. (2020). Hyper-Temporal Remote Sensing Data In Bare Soil Period And Terrain Attributes For Digital Soil Mapping In The Black Soil Regions Of China. Catena, 184, 104259.

Yang, Z., Witharana, C., Hurd, J., Wang, K., Hao, R., & Tong, S. (2020). Using Landsat 8 Data To Compare Percent Impervious Surface Area And Normalized Difference Vegetation Index As Indicators Of Urban Heat Island Effects In Connecticut, Usa. Environmental Earth Sciences, 79(18), 1-13.

Yeşilyurt, G., & Ertürk, A. (2018, May). Path Opening Based Road Extraction For Gokturk-2 Images. In 2018 26th Signal Processing And Communications Applications Conference (Siu) (Pp. 1-4). Ieee.

Yiğit A.Y. (2020). İnsansız Hava Aracı İle Elde Edilen Veriler Yardımıyla Yol Tespiti, Yüksek Lisans Tezi, Afyon Kocatepe Üniversitesi, Türkiye.

Zaitunah, A., Samsuri, A. A., & Safitri, R. A. (2018, March). Normalized Difference Vegetation Index (Ndvi) Analysis For Land Cover Types Using Landsat 8 Oli In Besitang Watershed, Indonesia. In Iop Conference Series: Earth And Environmental Science (Vol. 126, No. 1, Pp. 1-9).

Zhang, M., Lin, H., Sun, H., & Cai, Y. (2019). Estimation Of Vegetation Productivity Using A Landsat 8 Time Series In A Heavily Urbanized Area, Central China. Remote Sensing, 11(2), 133.

Zhou, T., Li, Z., & Pan, J. (2018). Multi-Feature Classification Of Multi-Sensor Satellite Imagery Based On Dual-Polarimetric Sentinel-1a, Landsat-8 Oli, And Hyperion Images For Urban Land-Cover Classification. Sensors, 18(2), 373.



