



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



**İNSANSIZ HAVA ARAÇLARI
KULLANILARAK MULTİ-SPEKTRAL
KAMERALAR İLE BİTKİ ÖRTÜSÜ
TÜRLERİNİN AYIRT EDİLMESİ VE
SINIFLANDIRILMASI**

Yusuf DOĞAN

YÜKSEK LİSANS TEZİ

Harita Mühendisliği Anabilim Dalı

Temmuz-2019
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Yusuf DOĞAN tarafından hazırlanan “İnsansız Hava Araçları Kullanılarak Multi-Spektral Kameralar İle Bitki Örtüsü Türlerinin Ayırt Edilmesi ve Sınıflandırılması” adlı tez çalışması 12/07/2019 tarihinde aşağıdaki jüri tarafından oy birliği / ~~oy çokluğu~~ ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Harita Mühendisliği Anabilim Dalı'nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

Başkan

Prof. Dr. Murat YAKAR

Danışman

Prof. Dr. Ferruh YILDIZ

Üye

Dr. Öğr. Üyesi Lütfiye KARASAKA

İmza






Yukarıdaki sonucu onaylarım.


Prof. Dr. Hakan KARABÖRK
Enstitü Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.


Yusuf DOĞAN

Tarih: 01.08.2019

ÖZET

YÜKSEK LİSANS TEZİ

İNSANSIZ HAVA ARAÇLARI KULLANILARAK MULTİ-SPEKTRAL KAMERALAR İLE BİTKİ ÖRTÜSÜ TÜRLERİNİN AYIRT EDİLMESİ VE SINIFLANDIRILMASI

Yusuf DOĞAN

Konya Teknik Üniversitesi
Lisansüstü Eğitim Enstitüsü
Harita Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Ferruh YILDIZ

2019, 73 Sayfa

Jüri
Prof. Dr. Ferruh YILDIZ
Prof. Dr. Murat YAKAR
Dr. Öğr. Üyesi Lütfiye KARASAKA

Günümüzde yeryüzündeki bitki örtüsü türlerinin ayırt edilmesi uzaktan algılama çalışmalarında yoğun olarak kullanılmaktadır. Uydu görüntüleri kullanılarak yapılan bu uzaktan algılama çalışmaları, uyduların gerek her zaman aynı yerden görüntü elde edememesi gerekse yer örnekleme aralıklarından kaynaklanan sebeplerle zamansal ve mekânsal çözünürlükleri yüksek hassasiyet ve doğruluk istenen çalışmalarda yetersiz kalmaktadır. Bu yüzden çalışmamızda, son zamanlarda hızla artan ve yaygınlaşan İHA (İnsansız Hava Aracı) teknolojisi esnek hareket kabiliyetine sahip olması nedeniyle tercih edilmiştir. Son on yılda İHA teknolojisinin gelişmesi ile kullanımı birçok sivil uygulama alanında yaygınlaştığı gibi tarım faaliyetlerinde de yaygınlaşmıştır. İlaçlama, arazi kullanımı tespiti, kuraklık zararı tespiti, bitki sağlığının izlenmesi gibi birçok tarımsal faaliyetlerde kullanımı söz konusudur. İHA'lara monte edilen multispektral kameralar ile arazi kullanımı ve bitki örtüsü türlerinin tespiti mümkün olmaktadır. Bu çalışmada bitki türünün tespit edilerek haritada gösterilmesi amacıyla yonca ve soya bitkilerinin ekildiği araziden multispektral görüntüler elde edildi. Görüntüler çeşitli yazılımlarda işlenerek üç farklı algoritma ile sınıflandırıldı. Bu sınıflandırma çalışmalarının doğruluğu incelendi. Yapılan sınıflandırmalarda aynı eğitim bölgeleri ve örneklem noktaları kullanıldı. Sınıflandırmalar sonucu Maximum Likelihood için doğruluk %87, Support Vector Machine için ise %81 olarak hesaplandı. Bu istatistiki bilgilere göre çalışmamız için en iyi sonucu veren sınıflandırma algoritmasının Maximum Likelihood olduğu ortaya çıkmıştır.

Anahtar Kelimeler: Bitki Türü Tespiti, İHA, Multispektral Görüntüleme, Sınıflandırma, Uzaktan Algılama

ABSTRACT

MS THESIS

**DISCRIMINATION AND CLASSIFICATION OF VEGETATION SPECIES
WITH MULTI-SPECTRAL CAMERA BY USING UNMANNED AERIAL
VEHICLES**

Yusuf DOĞAN

**Konya Technical University
Institute of Graduate Studies
Department of Geomatic Engineering**

Advisor: Prof. Dr. Ferruh YILDIZ

2019, 73 Pages

Jury

Prof. Dr. Ferruh YILDIZ

Prof. Dr. Murat YAKAR

Asst. Prof. Dr. Lütfiye KARASAKA

Nowadays, discrimination of vegetation species on earth is used extensively in remote sensing studies. Remote sensing studies using satellite imagery are inadequate in studies where high accuracy of spatial and temporal resolutions are required due to the fact that satellites are not always able to obtain images from the same location and due to ground sampling distance. Therefore, in our study, UAV (Unmanned Aerial Vehicle) technology, which has been increasing and becoming widespread recently, has been preferred because of its flexible mobility. In the last decade, with the development of UAV technology, its use has become widespread in many civil application areas as well as in agricultural activities. It is used in many agricultural activities such as disinfestation, land use detection, drought damage detection, plant health monitoring. Multispectral cameras mounted in UAVs enable the identification of land use and vegetation types. In this study, multispectral images were obtained from the field where clover and soybean plants were planted in order to identify the plant species on the map. Images were processed in various software and classified with three different algorithms. The accuracy of these classification studies was examined. The same training sites and random sampling points were used in the classifications. As a result of the classifications, accuracy was calculated as 87% for Maximum Likelihood and 81% for Support Vector Machine. According to this statistical information, the best-performing classification algorithm for our study was observed to be is Maximum Likelihood.

Keywords: Classification, Discrimination of Vegetation, Multispectral Visualization, UAV

ÖNSÖZ

Bu çalışmanın ortaya çıkarılmasında önemli katkıları olan ve desteğini esirgemeyen tez danışmanım Prof. Dr. Ferruh YILDIZ'a teşekkürlerimi sunmayı bir borç bilirim. Çalışmalarım boyunca maddi ve manevi yönden her zaman yanımda olup verdikleri desteklerinden dolayı sevgili Eşim'e ve aileme sonsuz teşekkürler...

Bu çalışmanın başından sonuna kadar yol gösteren Prof. Dr. Murat YAKAR, Dr. Öğretim Üyesi Lütfiye KUŞAK ve Dr. Öğretim Üyesi Fatma BÜNYAN ÜNEL hocalarıma teşekkür ederim. Arazi çalışmalarında yardımlarını esirgemeyen Alata Bahçe Kùltürleri Araştırma Enstitüsü personellerine teşekkürü borç bilirim.

Yusuf DOĞAN
KONYA-2019

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
SİMGELER VE KISALTMALAR	viii
1. GİRİŞ VE KAYNAK ARAŞTIRMASI	1
2. MATERYAL VE YÖNTEM.....	4
2.1. Uzaktan Algılama	4
2.1.1. Uzaktan algılamada sensör sistemleri.....	6
2.1.2. Uzaktan algılamada insansız hava araçlarının kullanımı.....	15
2.2. İnsansız Hava Araçları.....	18
2.3. Uzaktan Algılamada Sınıflandırma	20
2.3.1. Piksel tabanlı sınıflandırma	21
2.3.2. Nesne tabanlı sınıflandırma	26
3. UYGULAMA	27
3.1. Donanım.....	27
3.2. Çalışma Alanı	30
3.3. Arazi Çalışması.....	31
3.4. Görüntülerin İşlenmesi ve Değerlendirilmesi.....	33
3.4.1. Pix4D	34
3.4.2. ArcGIS	40
3.4.3. Kontrolsüz Sınıflandırma Çalışmaları	44
3.4.4. Kontrollü Sınıflandırma Çalışmaları	45
4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....	48
5. SONUÇLAR VE ÖNERİLER	54
KAYNAKLAR	56
EKLER	60
ÖZGEÇMİŞ	73

SİMGELER VE KISALTMALAR

Simgeler

µm	:	mikrometre, mikron
mm	:	milimetre
cm	:	santimetre
m	:	metre
°C	:	santigrad derece

Kısaltmalar

CBS	:	Coğrafi Bilgi Sistemleri
CCD	:	Charged-Coupled Device
CMOS	:	Complementary Metal-Oxide-Semiconductor
DSLR	:	Digital Single-Lens Reflex
DSM	:	Digital Surface Model
GIS	:	Geographic Information System
GSD	:	Ground Sample Distance
HALE	:	High Altitude Long Endurance
ICAO	:	International Civil Aviation Organisation - Uluslararası Sivil Havacılık Organizasyonu
ISPRS	:	International Society for Photogrammetry and Remote Sensing
İHA	:	İnsansız Hava Aracı
LiDAR	:	Light Detection and Ranging
MALE	:	Medium Altitude Long Endurance
MAV	:	Mikro UAV
MUAV	:	Mini UAV
NAV	:	Nano UAV
NDVI	:	Normalized Difference Vegetation Index
NIR	:	Near-Infrared
RGB	:	Red-Green-Blue, Kırmızı-Yeşil-Mavi
RPAS	:	Remotely Piloted Aircraft Systems
RPH	:	Remotely Piloted Helicopter
RPV	:	Remotely Piloted Vehicle
SAR	:	Synthetic Aperture Radar – Sentetik Açıklıklı Radar
SfM	:	Structure from Motion
SHGM	:	Sivil Havacılık Genel Müdürlüğü
SHT-İHA	:	Sivil Havacılık İHA Talimatı
SİHA	:	Silahlı İHA
SVM	:	Support Vector Machine
TUAV	:	Tactical UAV
UAS	:	Unmanned Aircraft Systems
UAV	:	Unmanned Aerial Vehicle) Uninhabited Air Vehicle
UCAV	:	Unmanned Combat Air Vehicle
UMA	:	Unmanned Aerial Vehicle
USAF	:	United States Air Force – Birleşik Devletler Hava Kuvvetleri
VTUAV	:	Vertical Take-off UAV
YKN	:	Yer Kontrol Noktası
YÖA	:	Yer Örnekleme Aralığı

1. GİRİŞ VE KAYNAK ARAŞTIRMASI

Günümüzde yeryüzündeki bitki örtüsü türlerinin ayırt edilmesi çalışmalarında uzaktan algılama yoğun olarak kullanılmaktadır. Genellikle uydu görüntüleri kullanılarak yapılan uzaktan algılama çalışmaları, uyduların gerek her zaman aynı yerden görüntü elde edememesi gerekse yer örnekleme aralıklarından (YÖA) kaynaklanan sebeplerle zamansal ve mekânsal çözünürlükleri yüksek hassasiyet ve doğruluk istenen çalışmalarda yetersiz kalmaktadır. Bu yüzden çalışmamızda, son zamanlarda hızla artan ve yaygınlaşan İHA (İnsansız Hava Aracı) teknolojisi esnek hareket kabiliyetine sahip olması nedeniyle tercih edilmiştir. İHA'ların istenilen zaman ve yer örnekleme aralığına uygun yükseklikte uçurulabilmesi esnek hareket kabiliyetine sahip olmasını sağlamaktadır. İHA üzerine yerleştirilen multispektral kameradan elde edilen görüntüler ile yeryüzündeki bitki örtüsü türlerinin tespiti yapıp sınıflandırılarak arazi kullanımlarının belirlenmesi, yasadışı bitki üretimlerinin tespit edilmesi ve ürün verimliliği gibi konulardaki ihtiyacın karşılanabileceği kanaati dünya genelinde giderek yaygınlaşmaktadır (Calderón ve ark., 2014; Barrero ve Perdomo, 2018; Jurado-Expósito ve ark., 2019).

İHA'lar genellikle küçük alanlarda hızlı veri toplama, yüksek doğruluklu düşük maliyetli haritalama için uygun olduğundan çeşitli uygulamalar için kullanılabilir (Ahmad ve ark., 2013). İHA tabanlı spektral görüntüleme kullanımı, yüksek çözünürlüklü uzaktan algılama uygulamalarında önemli avantajlar sunmaktadır. Bununla birlikte, bir İHA üzerine monte edilebilen sensörlerin sayısı sınırlıdır ve spektral bantların optimal kombinasyonunun seçilmesi karmaşıktır ancak geleneksel İHA-tabanlı multispektral görüntüleme sistemleri için çok önemlidir (Ishida ve ark., 2018). Bitki örtüsünü ayırt etme yeteneği, İHA'ların görüntü spektrumu (kamera tipi), mekânsal (uçuş yüksekliği) ve zamansal (çalışma tarihi) çözünürlüklerinden önemli ölçüde etkilenmiştir (Peña ve ark., 2015). Küçük termal, lazer veya spektral sensörler ile donatılmış insansız hava araçlarının kullanımı, meralar, ormanlar ve tarımsal ortamlardaki uygulamaların modellenmesi, haritalanması ve izlenmesi için umut verici bir alternatif olarak ortaya çıkmıştır (Salamí ve ark., 2014). Bitki örtüsü tespiti için İHA'lara monte edilen sensör sistemleri genellikle pasif sistemler olup güneşten yansıyan ışınları kullanırlar. Pasif optik sistemler ve özellikle hiperspektral sistemler genel olarak aktif SAR veya LIDAR sensör sistemlerine göre ağaç türlerinin sınıflandırılması için daha yüksek potansiyel göstermiştir (Fassnacht ve ark., 2016).

Somers ve Asner (2014) çalışmalarında spektral ve zamansal verileri kullanarak irdeledikleri yaklaşımları sonucunda her pikselde mevcut olan ağaç türleri arasındaki spektral ayrımı optimize edebildiklerini belirtmektedir. Bitki türlerinin spektrumlara göre ayırt edilmesi konusunda yapılan çalışmalarda kırmızı kenar spektrumunun oldukça etkili olduğu gözlemlenmiştir. Kırmızı kenar spektrumu bitki örtüsü yapı parametrelerine duyarlıdır, bitkilerin geniş yaprak ve Yaprak Alan Endeksi (LAI) bitkinin ayırt edilmesi için kırmızı kenar bölgesini iyi bir seçim haline getirmektedir (Jia ve ark., 2011).

Adam ve Mutanga (2009) yeşil yaprakların yakın kızılötesi ve kırmızı kenar bölgelerinde en büyük çeşitliliğe sahip olduğunu belirterek elektromanyetik spektrumun kırmızı kenar ve kızıl ötesi bölgelerinin tür tespiti ve ayırt etmedeki önemini çalışmalarında doğrulamıştır. Bitki örtüsü ayırt edilmesinde birçok sınıflandırma tekniği kullanılmaktadır. Dudley ve ark. (2015) bitki örtüsü fenolojisindeki mekânsal ve zamansal değişimlere bağlı olarak spektral yansımadaki değişkenlik sebebiyle doğru bitki örtüsü sınıflandırmasında oluşan sorunlara çözüm bulmak için Çoklu Son Eleman Spektral Karışım Analizi (MESMA) yöntemini kullanmışlardır. Tuz bataklıkları bitki toplulukları üzerinde yapılan bir çalışmada Doğrusal Ayrıcı Analiz (LDA) ve parametrik olmayan sınıflandırma ve regresyon ağacı (CART) tekniklerinin karşılaştırması yapılmıştır. Kahve tarlaları ve doğal bitki örtüsü arasında ayırım yapmanın zor olduğu bölgelerde yapılan bir çalışmada kontrollü sınıflandırma tekniği kullanılmıştır (Martínez-Verduzco ve ark., 2012). Anchang ve ark. (2016) uydu görüntülerinden kentsel bitki örtüsü haritalama çalışmalarında kontrolsüz sınıflandırmanın maliyetli alan çalışmasından ziyade görüntü elde etmede kaynaklara daha fazla odaklanmasını sağladığından bir avantaj sağladığını belirtmektedir. Sınıflandırma çalışmalarında bitki türlerine göre yukarıdakiler gibi çeşitli teknikler kullanılmaktadır.

Ayrıca İHA'ların mekânsal çözünürlükte avantaj sağlamasının spektral çözünürlüğü de doğru orantılı olarak avantajlı kılıp kılmayacağı da tez çalışması kapsamında değerlendirilecektir. Çalışmada yeryüzündeki bitki örtüsü türlerinin belirlenmesi ve sınıflandırılması yapılarak arazi kullanımına yönelik yüksek hassasiyet ve doğrulukta haritaların oluşturulması amaçlanmaktadır. Bu amaçla İHA üzerine yerleştirilecek multispektral kamera ile elde edilecek görüntülerden araziye ait bitki örtüsü indeksi kullanılarak mekânsal çözünürlüğü yüksek ortofotoların üretilmesi hedeflenmektedir.

Tez çalışmasında, uzaktan algılamanın bu çalışma ile ilişkisi, İHA'ların tarım uygulamalarındaki yeri ve multispektral sensörlerin bilgi toplama mantığı anlatılmıştır. Uygulamaya yonca ve soya bitkilerinin arazide tespit edilip sınıflandırılması amacıyla İHA platformuna entegreli multispektral kamera ile görüntülerinin elde edilmesiyle başlanmıştır. Hava fotogrametrisi tekniğine uygun olarak elde edilen görüntüler dengeleme, nokta bulutu ve ortofoto mozaik oluşturma işlemlerine tabi tutulmuştur. Yeşil, kırmızı, kızıl-kenar ve kızılötesi bantlarda ayrı ayrı oluşturulan ortofoto görüntüler birleştirilerek sınıflandırma haritaları üretilmiştir. Bu haritaları üretmek için Maximum Likelihood ve Support Vector Machine kontrollü sınıflandırma yöntemleri ve ISO-data cluster kontrolsüz sınıflandırma yöntemi kullanılmıştır. Sınıflandırma haritalarının doğruluğu araştırılmış ve Maximum Likelihood için %87, Support Vector Machine için ise %81 oranında hesaplanmıştır. Elde edilen istatistiki bilgilere göre bu çalışma için en iyi sonucu veren sınıflandırma algoritmasının Maximum Likelihood olduğu ortaya çıkmıştır. Çalışmada bitki türleri sınıflandırma haritalarının oluşturulmasında İHA ve multispektral kameraların etkisi incelenmiştir.

2. MATERYAL VE YÖNTEM

Bu bölümde çalışmada kullanılan materyal ve yöntemlerin teorik altyapısından bahsedilmektedir. Veri elde etme yöntemi olarak fotogrametri kullanılmıştır. Verilerin işlenip bilgiye dönüştürülmesi ise uzaktan algılama ve sınıflandırma yöntemiyle sağlanmıştır. Verilerin elde edilmesinde kullanılan materyaller ise bir insansız hava aracı platformu ve multispektral kameradır.


2.1. Uzaktan Algılama

Uzaktan algılama çalışmaları fotoğraf makinesinin icadından kısa bir süre sonra başlamıştır. O günlerden günümüze kadar uzaktan algılama için sıcak hava balonu, zeplin, güvercin, uçak ve son olarak yer sathını gözleme uyduları gibi birçok platform kullanılmıştır. Teknolojinin gelişmesine paralel olarak uzaktan algılama çalışmalarında elektromanyetik enerji kullanımı yaygınlaşmıştır. Uzaktan algılama, arada mekanik bir temas olmaksızın bir cisimden yayılan veya yansıtılan elektromanyetik ışınımın nitelik ve nicelik yönünden değerlendirilmesiyle cismin özelliklerinin uzaktan ortaya konması ve ölçülmesidir (Sunar ve ark., 2011). Bu tanımın içine elektromanyetik ışınımın ve akustik enerjinin veya nükleer ışınımın veya bir ortamdaki kuvvet alanlarının algılanması da girer. Tanımda cismin kendisinin bir ışınım yayması koşulu, cisim ile alıcı arasındaki uzaklık için de bir kısıtlama yoktur. Ölçmeler, deri altındaki bir tümörün yerinin saptanması amacı ile derinin algılanmasında olduğu üzere çok yakından veya uzay araçları ile algılamada olduğu üzere çok uzaklardan yapılabilir. İnsan hayatında ışığın göz ile görülmesi, ısının deri ile hissedilmesi, sesin kulak ile duyulması esasında uzaktan algılama işlemleridir (Örmeci, 1987). Uzaktan algılama genellikle yeryüzüne dönük olarak havadan veya uzaydan yapılmaktadır. Algılama cisimlerle fiziksel temasa geçilmeden gerçekleştirilir (Sesören, 1998).

Tüm uzaktan algılama teknolojileri belirli temel kavramlara dayalı olup aynı temel bileşenleri içermektedir. Sistemdeki temel bileşenler; hedef, enerji kaynağı, iletim (yayımlı) yolu ve bir algılayıcıdır. Hedef ilgilenilen bir yeryüzü cismi veya materyaldir. Sistemde hedefi aydınlatan veya elektromanyetik enerji sağlayan bir enerji kaynağı olmalıdır. Bu enerji, hedefin özellikleri ve gelen ışınımına bağlı olarak hedef ile etkileşimde bulunup hedeften algılayıcıya bilginin iletilmesi için bir iletim (yayımlı) ortamı olarak hareket edecektir. Algılayıcı ise hedeften gelen ışınımı ölçen ve kaydeden

bir aygıttır. Hedeften gelen enerji kaydedildikten sonra yer istasyonuna iletilerek görüntü formatına dönüştürülmek üzere işlenir. Daha sonra hedef hakkında bilgi çıkarmaya yönelik görsel olarak yorumlanır veya elektronik olarak işlenir (Sunar ve ark., 2011)

Elektromanyetik enerji doğada iletim, taşınım ve ışıma yoluyla yayılır. Uzaktan algılamayı enerjinin ışıma yoluyla taşınması ilgilendirir. Elektromanyetik ışıma enerjinin uzayda dalgalar ya da tanecikler halinde yayılmasıdır. Herhangi bir maddeden enerji yayılması bu tanımın kapsamındadır. Uzayda dalgalar halinde yayılan enerjinin dalga uzunluklarına göre ayrılarak incelenen ortama elektromanyetik spektrum (tayf) denir. Dalga uzunluğu nanometrelerden kilometrelere kadar olan sürekli bir enerji ortamıdır.



Şekil 2.1. Elektromanyetik Spektrum (Wikipedia, 2009)

Uzaktan algılamada yer sathını gözlem uyduları tarafından kullanılan dalga boyları atmosferden geçebilme özelliğine göre değişiklik göstermektedir. Güneşten yayılan enerjinin bir kısmı atmosfer tarafından dünyaya ulaşmadan yansır veya emilir. Bir kısmı atmosferden geçerek yeryüzü tarafından emilir, yeryüzünden yansıyan enerjinin bir kısmı ise atmosferden uzaya geçerken emilir ve kalan enerji uydular tarafından algılanır. Şekil 2.1'de görüldüğü üzere görünür ışık, kızılötesi ve radyo dalgaları atmosferden geçerek uydular tarafından algılanır.


Uzaktan algılamada genel olarak uydulardan elde edilen görüntülerden faydalanılsa da uçaklardan alınan görüntüler de kullanılmaktadır. Son zamanlarda İHA sistemlerinin gelişmesi ve yaygınlaşmasıyla bu sistemler de kullanılmaktadır.

2.1.1. Uzaktan algılamada sensör sistemleri

Uzaktan algılama literatüründe algılayıcı sistemlerin bir elemanı olan sensörler dijital teknolojinin gelişmesi ile ön plana çıkmıştır. Daha önceleri fotoğraf filmleri ile gerçekleştirilen algılama çalışmaları günümüzde yerini dijital sensör teknolojisine bırakmıştır. Algılayıcı sistemler tarama yapan ve tarama yapmayan olarak iki kısımda sınıflandırılır. Sunar ve ark. (2011) bu sistemleri şu şekilde tanımlamaktadır. “*Tarama yapma özelliği belirli bir zamanda görüntü boyunca algılayıcının hareket etmesini, tarama yapmama özelliği ise algılayıcının görüntü üzerinde sabit tutulmasını ya da çok kısa anlık bir zamanda ilgilenilen hedefi algılamasını ifade eder.*” Bir fotoğraf makinesi tarama yapmayan algılayıcıya örnek olarak gösterilebilir. Deklanşöre basıldığı anda objektif açılır ve kapanır bu sürede alınan ışık sensör tarafından algılanır. Tarama yapan sistemlerin çalışma prensibi ise bilgisayara bağlı belge tarayıcı cihazlar ile aynıdır. Algılayıcı platformunun uçuş doğrultusuna dik yönde ince şeritler halinde tarayarak görüntü elde edilmesini mümkün kılar.


2.1.1.1. Görüntüleme araçları

Fotoğraf kamerasının icadıyla birlikte başlayan uzaktan algılama çalışmaları teknolojinin hızla gelişmesiyle birlikte yeni tip sensör sistemlerinin oluşmasına yol açmıştır (Şekil 2.2).




Şekil 2.2. Uzaktan algılamada kullanılan görüntüleme araçları (Jensen, 2007)

Sayısal kameralarda filmlerin yerine ışığa duyarlı sensörler bulunmaktadır. Bu sensörler optik algılayıcı adı verilen dijital hücrelerden oluşur. Bu hücreler fotosite adı verilen foton algılayıcı ufak ışık kovuklarının milyonlarcasının yan yana dizilmesiyle oluşur. Kamera deklanşörüne basılıp pozlama başladığı zaman hücrelerin her biri foton toplamak için açılır ve fotonları elektrik sinyali olarak depolar. Pozlama bittiğinde, kamera her bir fotositeyi kapatır ve akabinde elektrik sinyalinin gücünü ölçmek suretiyle her bir hücre içine ne kadar foton düştüğünü belirlemeye çalışır. Sinyallerin miktarı bit derinliği yoluyla saptanan bir hassasiyetle dijital değer olarak belirlenir.




Şekil 2.3. a) Hücre dizileri, b) Işık hücreleri – fotosite. (McHugh, 2019)

Şekil 2.3’de tasvir edilen hücreler kırmızı, yeşil ve mavi renklerin ne kadarını topladığını ayırt edemediğinden dolayı sadece gri tonlu görüntüler oluşturur. Renkli görüntü elde etmek için, her bir hücre üzerine ışığın belirli renklerinin geçmesine izin veren bir filtre yerleştirilir. Son zamanlarda üretilen tüm sayısal kameralar her hücrede üç ana rengin sadece birini yakalar ve gelen ışığın aşağı yukarı üçte ikisini ayırır. Sonuç itibarıyla, her pikselde tam renk elde edebilmek amacıyla kameranın diğer iki ana rengi yaklaşık olarak ayarlaması gerekir. Renkli filtre dizilerinin en yaygın tipi Bayer dizisi olarak bilinir (Şekil 2.4).




Şekil 2.4. a) Renkli filtre dizisi, b) Renkli filtreli fotosite. (McHugh, 2019)

Bayer dizisi, dönüşümlü kırmızı-yeşil ve yeşil-kırmızı filtre sıralarından oluşur. Bu sıralama düzenine göre kırmızı ve mavi sensörlerin iki katı kadar yeşil sensör bulunmaktadır. Böylece hiçbir ana renk toplam alana eşit olarak dağılmaz. Bunun sebebi ise insan gözünün yeşil ışığa, kırmızı ve mavi ışıktan daha duyarlı olmasıdır. Yeşil piksellerin fazla olması her bir rengin eşit olarak işlendiğinde elde edilebilecek olandan daha iyi detaylara sahip ve daha az gürültülü görünen bir görüntü üretilmesini sağlar. Bu ise yeşil banttaki gürültünün diğer iki ana renginkinden daha az olma sebebini açıklamaktadır.




Şekil 2.5. Bayer dizisinin 2x2 diziler halinde ayrılması (McHugh, 2019)

Nihai görüntünün oluşabilmesi için Bayer dizisindeki ana renklerin her bir pikselde tam renk bilgisine çevrilmesi gerekmektedir. Bunu anlamının yolu her 2x2 RGB diziyi tek bir tam renkli hücre olarak düşünmektir. Görüntü işlemcisi yüksek çözünürlüklü görüntü elde etmek için piksel değerlerini yatay ve düşey yönlerde bindirmeli 2x2 diziler şeklinde interpolasyon yapmak suretiyle hesaplar (Şekil 2.5 ve 2.6) (McHugh, 2019).



Şekil 2.6. Piksel değerleri diziler arasında yatay ve düşey yönlerde bindirmeli olarak interpolasyon ile hesaplanır. (McHugh, 2019)

En yaygın kullanılan hücre dizileri CCD (charged coupled device) ve CMOS (complementary metal-oxide-semiconductor) sensörlerdir (Şekil 2.7). Her iki sensör tipi ışığı bayer dizisi prensibine göre algılar ve tutar. Ancak aralarında donanımsal farklılıklar bulunmaktadır. CCD sensörlerin hammaddesi ışığa karşı hassas bir yapıya sahip olan silikon yarı-iletken maddelerdir. Bu hassasiyetleri sayesinde ışığı elektronik sinyallere dönüştürüp işlenmek üzere kameranın işlemcilerine gönderirler. Görüntü işlemci üzerinde işlenen sinyaller dijital sinyale dönüştürülüp hafıza kartlarında depolanır. CCD sensörler oldukça fazla enerji harcarlar ve kullanım alanları oldukça büyüktür. Bu sensörler CMOS sensörlere nispeten daha pahalı olup daha kaliteli ve net görüntü verdiği için orta format kameralarda daha çok tercih edilirler.




Şekil 2.7. CCD (a) ve CMOS (b) sensör

CMOS sensörler tıpkı CCD'ler gibi ışığı elektronik sinyallere dönüştürür. Bu sensörler yüzlerce transistörden oluşur ve her bir piksel ayrı bir transistör tarafından meydana getirilir. CMOS sensörleri üretmek daha kolay olduğu için CCD sensörlere nispetle daha ucuzdur. Bu da dijital kameraların ucuzlamasına neden olmuştur. Bu iki sensör tipi arasındaki en büyük fark CCD sensörlerin düşük parazitli yüksek kaliteli görüntüler oluşturmasıdır. CMOS sensörlerin ürettiği görüntüler parazitli olmaya daha meyillidir. CCD sensörleri ışığa karşı daha duyarlıdır. CMOS sensörleri kullanılan kameralarda düşük parazitli görüntü sağlamak için daha fazla ortam ışığına ihtiyaç vardır.

CCD ve CMOS sensörler yakın kızılötesi (NIR) ışığa karşı duyarlıdır. CCD sensörler sahip oldukları ışık hassasiyeti yakın kızılötesi görüntüleme uygulamaları ve yüksek görüntü kalitesi gerektiren uygulamalar için oldukça kullanışlıdır. CCD

sensörlerin spektral duyarlılığı CMOS sensörlere göre daha fazla olup her ikisi de 400 – 1000 nm dalgaboyları arasında algılama yapmaktadır (Şekil 2.8). Bu sensörler tarafından oluşturulan görüntülerde NIR ışık bilgileri de bulunur. Bu yüzden oluşan görüntü yalancı renkli görüntüdür. Gerçek renkli görüntü elde etmek için sensörün hemen önüne NIR ışığı engelleyen filtreler yerleştirilir. Bu sayede NIR ışık sensöre ulaşmayıp sadece mavi, yeşil ve kırmızı renkler ulaşabildiği için gerçek görüntü elde edilir. Son zamanlarda CCD sensör kalitesine yaklaşan CMOS sensörlerin kullanımı birçok görüntüleme uygulaması için giderek yaygınlaşmaktadır.



Şekil 2.8. İnsan gözü, CCD ve CMOS sensörlerin spektral duyarlılığı

2.1.1.2. Tarayıcı sistemler

Uzaktan algılama sensörlerinden birisi de scanner (tarayıcı) aletlerdir. Tarayıcılar fotoğrafik yöntemlerle sınırlanmış olan termal ve elektromanyetik spektrumun yayılan bölgesinde algılama yapabilme olanaklarını artırmak düşüncesiyle geliştirilmiştir. Günümüzde kullanılan tarayıcılar, line scanner (çizgi tarama) ve pushbroom (iterek tarama) sistemleri olarak ikiye ayrılır.

Çizgi tarama sisteminde bir motorun döndürdüğü tarayıcı ayna sistemin en önemli öğelerinden biridir. Bu ayna; ya 360 derece dönecek şekilde ya da küçük açılarla ileri geri hareketlerini tamamlayacak şekilde düzenlenmiştir. Bu tip algılama şekline optik-mekanik tarama denir. Optik tarama genellikle platformun hareket yönüne diktir. Belli bir açı altında birbirine paralel olarak yapılan taramalardan her birine çizgi (line)

denilir. Yeryüzünden yayılan enerji aletin döner aynası tarafından toplanarak optik sisteme aktarılır. Optik sistem toplanan enerjiyi bir sensör üzerine yönlendirir. Sensör, üzerine düşen termal ya da ışık enerjisini elektrik enerjisine dönüştürür. Bu elektrik sinyalleri bir manyetik teyp üzerine kaydedilir. Manyetik teyp üzerine düşen veriler analog ya da sayısal olarak kaydedilebilir.

İterek tarama sisteminde ise CCD sensörler kullanılır. CCD hücrelerinden binlercesi bir düzlem üzerinde olmak koşuluyla sıralar halinde dizilir. Algılanması istenen objelerden yansıyan ışıma bir optik sistem aracılığıyla bu hücrelerin üzerine düşürülür. Böylelikle herhangi bir ögeye gerek kalmaksızın nesne hücreler tarafından algılanır. Platform ileri doğru hareket ettiğinde hücreler de çabucak dolup boşalarak ışımayı doğrudan kolayca ölçer (Sesören, 1998).

2.1.1.3. Multispektral görüntüleme

Elektromanyetik spektrumun çoklu spektral bantlarında veya aynı spektral bant aralığında yer alan farklı renk ve dalga boyu bölgelerinde gerçekleştirilen veri toplama tekniğine multispektral görüntüleme denir. Multispektral görüntüleme tekniğinde görünür ışık ve ötesinde var olan ışınımın algılanması için belirli dalga boylarını geçiren filtreler ya da bu dalga boylarına duyarlı aletler kullanılır. Multispektral görüntüleme, kırmızı-yeşil-mavi renklerden oluşan görünür ışıktan başka insan gözünün algılayamadığı ultraviyole ve kızılötesi gibi dalga boylarına ait bilgilerin görünür hale getirilmesine izin verir. Multispektral görüntüler aynı yüzeyin farklı dalga boylarında görüntülenmesi ile oluşur. Genellikle yer sathını gözleme uydularında kullanılan sensörler vasıtasıyla görüntüleme işlemleri gerçekleştirilir. Örnek olarak Landsat 8 OLI (Operational Land Imager) uydusundan sağlanan multispektral görüntülerin elde edildiği 11 adet bant aralığı aşağıda verilmiştir (USGS, 2019).

- Band 1: Kıyı aerosol (0.43-0.45 μm)
- Band 2: Mavi (0.45-0.51 μm)
- Band 3: Yeşil (0.53-0.59 μm)
- Band 4: Kırmızı (0.64-0.67 μm)
- Band 5: NIR – Yakın Kızılötesi (0.85-0.88 μm)
- Band 6: Kısa-dalga Kızılötesi SWIR 1 (1.57-1.65 μm)
- Band 7: Kısa-dalga Kızılötesi SWIR 2 (2.11-2.29 μm)
- Band 8: Pankromatik (0.50-0.68 μm)
- Band 9: Sirkus bulutları (1.36-1.38 μm)
- Band 10: Termal Kızılötesi TIRS 1 (10.60-11.19 μm)
- Band 11: Termal Kızılötesi TIRS 2 (11.50-12.51 μm)




Şekil 2.9. İstanbul'un Landsat 5 uydusu tarafından elde edilen 2011 yılına ait multispektral görüntüsü (NASA, 2011)

Uydu ve hava aracı platformlarında her bant için ayrı ayrı sensör sistemleri yerleştirilerek birçok kullanım amacına hizmet eden görüntüler elde edilir (Şekil 2.9). Bu amaçlar bitki örtüsü tespiti, bitki sağlığı, kıyı şeridi değişimi, yerleşim alanlarının gelişiminin izlenmesi, bulutların izlenerek hava durumunun tahmin edilmesi, çevresel felaketlerin izlenmesi ve sebep olduğu zararların tespit edilmesi, küresel iklim değişikliği çalışmaları için veri sağlanması gibi çeşitli çalışmaları içermektedir. Farklı bantlardan elde edilen multispektral görüntülerin bilimsel hesaplamalarla oluşturulan kombinasyonları birçok ihtiyaca yönelik çalışmalar için kullanılmaktadır (Hayes ve Decker, 1998; Özkan, 2006; Özyavuz, 2011; Xie ve ark., 2018; Yılmaz ve Terzi, 2019).

Gözlemlenen sahanın, eşzamanlı olarak, iki ya da daha çok fotoğraflanmasıyla gerçekleşir. Multispektral fotoğraflama, multispektral kamera sistemleriyle yapılır. Kullanılan kameralar genelde “çok kamera sistemi”, “çok mercekli tek kamera sistemi” ve “modifiye yakın kızılötesi kamera” olarak adlandırılan üç sistemden oluşur.

Çok kamera sistemi 2, 3, 4 veya daha çok kameranın birleşmesinden oluşabilir (Şekil 2.10). Her ne kadar daha çok kamera kullanılması olanaklı ise de genellikle kameraları bir düzlem üzerinde tutabilme gibi bir sorunla karşılaşılabilir. Kameraların

bir düzlem üzerinde olmaması her şeyden önce ayrı kameralar tarafından görüntülenen aynı nesnelere arasında farklılıkların doğmasına neden olur.



Şekil 2.10. Çok kamera sistemi (Zhao ve ark., 2016)

Çok kamera sisteminde oluşan bütün güçlükler çok mercekli tek kamera sistemi kullanılarak giderilebilir. Tek kamerada birden çok optik sistemim bir araya getirilmesiyle oluşur. Her merceğin önüne farklı filtreler yerleştirilerek multispektral özellik kazandırılır. Bu sistemde bütün görüntüler tek bir film üzerine kaydedilir. Ancak sayısal kameralarda her merceğe karşılık bir sensör kullanılır. Tek bir odak düzleminin bulunmasından dolayı bütün bantların belirli bir diyafram açıklığında eşit pozlamaya bağlı tutulması sağlanmış olur (Sesören, 1998). Son yıllarda uydu ve uçak platformları için kullanılan kameralara nispeten daha küçük boyutlarda, İHA platformlarında kullanılabilir kameralar üretilmeye başlanmıştır (Şekil 2.11).



Şekil 2.11. İnsansız Hava Aracı platformlarında kullanılan bir multispektral kamera – Parrot Sequoia

Bu sistemlerin dışında modifiye kamera sistemleri, piyasada yaygın olarak kullanılan DSLR ve/veya Kompakt kameraların modifiye edilmesiyle elde edilir. Bilindiği üzere CCD ve CMOS sensörler NIR tayf bölgesindeki ışığa duyarlıdır. Gerçek görüntü elde etmek için sensör ile mercek arasına NIR filtre yerleştirilir. Bu filtre kaldırıldığı zaman NIR ışık sensör tarafından algılanabilir hale gelmektedir (Şekil 2.12). Elde edilen görüntü ise false-colour görüntü olarak kaydedilmektedir.

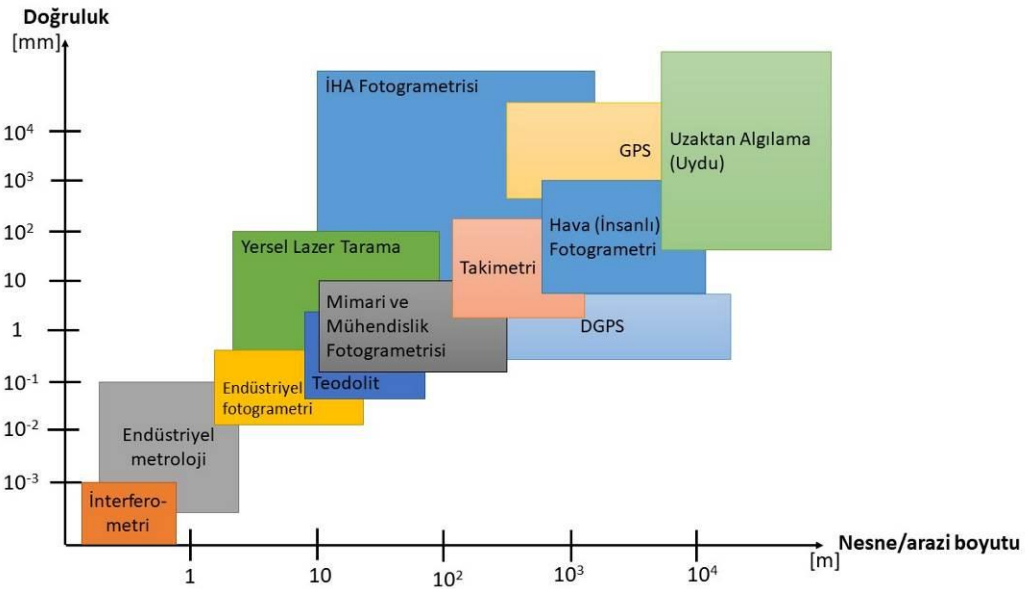


Şekil 2.12. Kızılötesi ya da hot mirror filtre

2.1.2. Uzaktan algılamada insansız hava araçlarının kullanımı

Uzaktan Algılama sistemleri uzayda farklı eğim ve yörüngelere oturtulan uydu platformlarında, atmosferin içinde hareket eden hava aracı platformlarında ve arazide yer-bazlı sistemlerde bulunmaktadır. En yaygın kullanılanı uydu ve uçak-bazlı sistemlerdir. Uçak-bazlı sistemler arasında İHA sistemleri de bulunmaktadır.

İHA teknolojisinin 2000’li yıllardan sonra hızla gelişmesiyle uzaktan algılama çalışmalarına dâhil edilmesi gayet doğal bir süreç olmuştur. Gözlem uyduları ve uçaklar üzerinde bulunan sensörler kullanılarak elde edilen ve çeşitli bilimsel ve profesyonel çalışmalar için kullanılan veriler İHA’lar vasıtasıyla da elde edilebilir hale gelmiştir. Ancak uydu ve uçaklarda bulunan büyük format kameralardan elde edilen verilere kıyasla İHA’ların taşıdığı küçük ve orta format kameralardan aynı ölçekte veri elde etmek için daha fazla görüntü toplanması gerekmektedir. Bu koşul özellikle düşük maliyetli mikro İHA kullanılan çalışmalarda geçerlidir. Şekil 2.13’de görüldüğü üzere İHA fotogrametrisi çalışmalarının kapladığı alan, geleneksel hava fotogrametrisi ve uzaktan algılama çalışmalarının kapladığı alana göre daha dardır. Ancak konum doğruluğunun nispeten biraz daha yüksek olduğu görülmektedir.



Şekil 2.13. Ölçüm yöntemlerinin doğruluklarının nesne/arazi boyutu ile ilişkisi. Luhmann ve ark. (2006)’dan düzenlenerek.

İstanbul'da düzenlenen ISPRS kongresinde İHA'lar uzak verileri elde etme kabiliyeti olan bir uzaktan algılama platformu olarak benimsenmiştir (Everaerts, 2008). Bholra ve ark. (2018) çalışmalarında uzaktan algılama yaklaşımıyla spektral-mekânsal yöntemler kullanarak İHA ile elde edilen görüntüler üzerinden elektrik iletim hatlarını tespit etmişlerdir. Gini ve ark. (2012) İHA sistemine entegre edilmiş RGB kamera ve modifiye NIR kamera ile yapmış oldukları 3B modelleme ve ağaç türlerinin sınıflandırılması çalışmalarında yüksek doğruluk ve hassasiyette harita üretmişlerdir. Büyük ölçekli harita üretimi için yapılan çalışmalarda ise yaklaşık 5 cm YÖA sağladığı ve uygun sıklıkta YKN kullanımı ile güçlü semantik bilgi elde edileceği görülmüştür (Karakış, 2012; Nex ve Remondino, 2014; Toprak, 2014). Yakar ve Doğan (2017) arkeolojik alanların haritalanması, yönetilmesi ve çalışma takibini etkin bir şekilde yapılması amacıyla İHA kullanımının avantajlarını ele almışlardır. Uzaktan algılama çalışmalarında İHA'ların tekrar uçuş periyotları kullanıcı kontrolünde olup düşük irtifalı uçuş yapabilme yeteneğinden dolayı sensörlerin arazi zeminini daha yakın konumlardan gözlemleyerek daha iyi konumsal veri toplanmasına olanak tanır, ayrıca bu sistemler klasik uzaktan algılama sistemlerine göre düşük maliyetlidir (Anderson ve Gaston, 2013). Uçak ve uydu platformlarının bir noktadan tekrar tekrar görüntü alması uçuş izni, maliyet ve zaman açısından İHA'lara göre daha zahmetlidir.

İnsansız hava araçlarının Uzaktan Algılamada kullanımı geri dönülemez bir noktaya girmiştir. Teknolojik gelişmeler göstermektedir ki İHA'lar Uzaktan Algılama çalışmalarındaki yerini hızla almaktadır.

2.1.2.1. İnsansız hava araçlarında kullanılan sensörler

İnsansız hava araçları sahip olduğu sınıf ve büyüklüğe bağlı olarak faydalı yük taşıma kapasitesine sahiptir. Kameralar İHA sistemlerinde uçuş görevlerini yerine getirmek için gerekli olan "faydalı yük" alt-sistemine dâhildir. İHA'larda kullanılan sensör tipleri sayısal kameralar kullanıldığından dolayı sayısal sensörlerdir (Şekil 2.19 ve 2.20). Bu sensörler HALE sınıfı İHA'lardan mikro İHA'lara kadar tüm sınıflarda kullanılabilir. Multispektral sensörler genellikle tarım uygulamalarında kullanılmaktadır. Bunun yanında arama kurtarma çalışmalarında termal kameralar da kullanılmaktadır. Bu sensörlerin küçük boyutta üretilip de kamera boyutlarının ve ağırlığının azalmasıyla piyasada yaygın olarak kullanılan multispektral kameralar İHA'lara monte edilmektedir. İHA sistemlerinde genellikle çok mercekli tek kamera

sistemi kullanıldığı gibi modifiye kameralar da kullanılmaktadır. Her iki kamera tipinin kullanımı hassas tarım uygulamaları için olmaktadır. (Austin, 2010; Primicerio ve ark., 2012; Anderson ve Gaston, 2013; Jiang ve ark., 2019).




Şekil 2.14. Oktokopter döner kanatlı mikro-İHA'ya monte edilmiş 6 bantlı multispektral sensörler (Lucieer ve ark., 2012)



Şekil 2.15. Mikro-İHA'lar için ufak boyutlu ve hafif MicaSense marka multispektral kamera

2.2. İnsansız Hava Araçları

İHA'lar kısaca üzerinde insan bulunmadan uçabilen, sabit veya döner kanatlı hava araçlarıdır (Eroğlu, 2013). Basitçe bir İHA hava aracına bakılacak olursa kabin ekibi kaldırılıp yerine bir bilgisayar sistemi ve radyo bağlantısı yerleştirilmiş hava araçlarıdır. Gerçekte ise bundan daha karmaşık bir durum söz konusudur ve hava aracı en başından itibaren kabin ve kabin ekibi olmayacak şekilde uygun olarak tasarlanmalıdır (Austin, 2010). Akyürek ve ark. (2012) İHA'yı kendi güç sistemi olan, ölümcül olan ve olmayan faydalı yük taşıyan, otomatik olarak veya uzaktan komuta sistemi ile uçurulan pilotsuz hava araçları olarak tanımlayıp bu araçların uçuşunu ve görevini mümkün kılan yer kontrol istasyonu (YKİ), yer veri terminali ve diğer teçhizatların eklenmesi ile oluşan sisteme ise İHA sistemleri olarak adlandırmaktadır (Şekil 2.16). Sivil Havacılık Genel Müdürlüğü'nün yayımladığı İnsansız Hava Araçları Talimatına göre İHA Sistemleri; İHA ile kontrol istasyonu, komuta ve kontrol veri bağı, kalkış ve iniş sistemi gibi uçuşun sağlanması için gerekli olan, birbirinden ayrı sistem elemanlarının bütünü olarak tanımlanmaktadır.



Şekil 2.16. İHA Sistemi

Model ve “drone” olarak adlandırılan hava araçlarından farklı olarak bir insansız hava aracı belirli bir zekâya sahiptir (Şekil 2.17). Kendisini kontrol eden bir insan unsuru ile iletişim kurabilir ve çektiği görüntüyü; pozisyon, hız, irtifa gibi kendisi ile ilgili bilgileri öngörülen yere aktarabilir. Bunların yanında kalan yakıt veya batarya

miktarı, motor sıcaklığı, hava sıcaklığı, rüzgârın yönü ve şiddeti gibi verileri de iletme kabiliyetine sahiptir (Kule, 2015). İHA'ların insanlı hava araçlarına kıyasla başlıca avantajları; İHA'lar ulaşılamayan alanlarda ve yüksek riskli durumlarda insan hayatını tehlikeye sokmadan kullanılabilir. Piyasadan temin edilebilen çoğu ticari İHA (Şekil 2.18) düşük maliyetli sistemlere yoğunlaşmakta olup İHA kullanımının önemli bir avantajı da maliyet faktörüdür ki, İHA'lar insanlı araçların sahip olduğu işletme maliyetlerinden daha düşük işletme maliyetine ve ucuzluğa sahiptir (Eisenbeiß, 2009).



Şekil 2.17. İHA'lar askeri ve sivil amaçlı olarak birçok alanda kullanılmaktadır.



Şekil 2.18. Quadcopter drone olarak adlandırılan döner kanatlı mikro-İHA

İHA terminolojisi son otuz yıllık süreçte pek çok değişikliğe uğramıştır. İHA'lar için başlarda RPV (Remotely Piloted Vehicle) tabiri kullanılmıştır. Sonradan kara ve deniz için uzaktan kumanda edilebilen araçların ortaya çıkmasıyla hava unsuru ön plana çıkarak bir süre UMA (Unmanned Aerial Vehicle) kullanılmıştır. Yerini UAV (Unmanned Aerial Vehicle) tabirine bırakmış olup sistemin tamamen otonom olmadığını, bir yerinde hala insan unsurunun mevcut olduğunu vurgulamak adına UAV (Uninhabited Air Vehicle – Yaşam Olmayan Hava Aracı) şeklinde de

yorumlanmaktadır. Birleşik Devletler Hava Kuvvetleri (USAF) ve Uluslararası Sivil Havacılık Organizasyonu (ICAO), RPAS (Remotely Piloted Aircraft Systems) tabirini tercih etmektedir. Son zamanlarda UAS (Unmanned Aircraft Systems) tabiri oldukça oturmuş olup devletlerin ve kurumların vizyonlarını ortaya koydukları yol haritalarında, resmi raporlarında ve havacılık endüstrisi yayınlarında yaygın olarak kullanılmaktadır (Kule, 2015).



Şekil 2.19. Türkiye’de üretilen Bayraktar İHA’lar

2.3. Uzaktan Algılamada Sınıflandırma


Sınıflandırma; birçok bilim dalında kullanılan bir karar verme işlemidir. Görüntü sınıflandırma işleminde amaç, bir görüntüdeki bütün pikselleri arazide karşılık geldikleri sınıflar veya temalar içine otomatik olarak atamak ve yerleştirmektir (Rashed ve Jürgens, 2010; Altunkaya ve Yastıklı, 2011). Uzaktan algılamada sınıflandırma, tematik bilgiyi oluşturan görüntüdeki anlamlı örüntü gruplarının belirlenmesi işlemidir. Bir başka deyişle farklı mekânsal, spektral, radyometrik ve zamansal bileşenleri olan görüntü verisinin farklı yüzey materyallerini ve durumlarını kategorize eden açıklayıcı etiketlere veya tematik bilgiye dönüştürülmesidir (Sunar ve ark., 2011). Bazı yöntemler doku ve içerik gibi görüntü özellikleri hakkında bilgi elde edebilmesine rağmen, görüntü sınıflandırmasının çoğu yalnızca arazi örtüsü sınıflarının spektral imzalarının tespitine dayanmaktadır.

Sınıflandırma yöntemleri piksel tabanlı ve nesne tabanlı olmak üzere ikiye ayrılmaktadır.

2.3.1. Piksel tabanlı sınıflandırma

Piksel tabanlı sınıflandırma, 1970'li yıllarda çok bantlı görüntülerin işlenmesiyle ilk kez geliştirilmeye başlanmış bir yöntemdir. Objelerin yansıma değerleri kullanılarak sınıflandırma yapılmaktadır. Bir pikselin ait olduğu sınıfa atama işlemi o piksele ait görüntü üzerindeki spektral yansıma değerine göre yapılır. İstatistiksel olarak her piksel benzer karakteristik özellik taşıyan gruba atanmaktadır (Altunkaya ve Yastıklı, 2011)

Piksel tabanlı sınıflandırmada görüntü pikselleri birbirinden bağımsız olarak içerdikleri spektral bilgi değerleri ile analiz edilir. Bu sınıflandırma için geleneksel yaklaşımdır, çünkü pikseller bir görüntünün temel (mekânsal) birimidir (Şekil 2.20). Sonuç olarak sayısal görüntünün temelinde ve doğasında pikseller bulunduğu için uygulanması genellikle kolaydır. Bu sınıflandırma yönteminde çeşitli teknikler kullanılır. Maximum-likelihood, minimum-distance-to-mean, minimum-mahalanobis-distance, K-mean cluster sadece bunlardan birkaçıdır. Bu yöntemde bilinmeyen piksele bu pikselin en büyük benzerlik değerine sahip olduğu sınıf etiketi atanır. Böyle bir sınıflandırma için özellik uzayı karar sınırları sabit ve tek anlamlıdır. Mekânsal çözünürlüğe bağlı olarak piksel alanı içinde sıklıkla farklı yüzey örtü tipleri bulunduğu için bu yaklaşım kolay uygulanabilir olmasına rağmen gerçek çevre şartlarına ve uzaktan algılama verisinin dijital karakterine uygun değildir. Diğer bir ifade ile yeryüzünde bir alana karşılık gelen pikselin homojen olmadığı durumda o piksele atanan parlaklık değeri de gerçekte bir karışımı temsil eder (Sunar ve ark., 2011).




Şekil 2.20. Bir yerleşim yerine ait multispektral uzaktan algılama verilerinden elde edilen sınıflandırma haritası (Ma ve ark., 2018)

Piksel tabanlı sınıflandırma Kontrolsüz (Unsupervised) ve Kontrollü (Supervised) olmak üzere ikiye ayrılır.

2.3.1.1. Kontrolsüz sınıflandırma

Herhangi bir öncül tematik bilginin kullanılmadığı kontrolsüz sınıflandırma yaklaşımında temel amaç, özellik uzayında belirli bir kıstası sağlayan doğal kümeleri ortaya çıkarmaktır. Benzer özellik vektörüne sahip olan örüntüler kendi aralarında bulutsu görünümde noktalar kümesi oluşturur. Her bir küme farklı bir nesne kategorisine ait örüntüler için çok boyutlu gösterim belirler. Sonuçta oluşan kümelerin hangi kategorilere ait olduğu bilinmemekte ancak arazi ölçümleri, harita ve hava fotoğraflarıyla kümelerin sınıf karşılıkları belirlenebilmektedir (Şekil 2.21).


En temel kontrolsüz sınıflandırma yöntemi K-means algoritmasıdır. Bu yöntemde örüntüler, seçilen küme merkezlerine olan uzaklıkları dikkate alınarak en yakın oldukları kümeye atanırlar. Öncül tematik bilgi olmadığı için küme merkezleri başlangıçta ya rastlantısal ya da sistematik olarak belirlenir. Daha sonra her bir kümeleme işleminden sonra küme merkezleri güncellenir. Böylece algoritma en uygun merkez değerlerini, diğer bir ifade ile örüntüler için en uygun küme etiketlerini iteratif olarak güncelleyerek elde eder. Uzaktan algılamada K-means algoritmasını temel alan ISODATA (Iterative Self Organizing DATA) yöntemi daha yaygın olarak kullanılmaktadır. Bu yöntemde oluşacak olan kümelerin piksel sayıları için alt limit ve belirli bir standart sapma değerine bağlı olarak üst limit belirlenebilir. Buna göre, kümeleme sonucunda sınıf sayısı istenenden az veya çok oluşabilir. Ayrıca işlemin sonlandırılmasında sadece iterasyon sayısı değil iterasyonlar arasındaki değişim oranı da kullanılabilir. Değişim oranı, yeni iterasyonla küme değerleri değişen piksel sayısının görüntüdeki oranıdır (Sunar ve ark., 2011).



Şekil 2.21. Kontrolsüz sınıflandırma yöntemiyle üretilmiş bir sınıflandırma haritası (Short ve Robinson, 1999)

2.3.1.2. Kontrollü sınıflandırma

Kontrollü sınıflandırma, bir kullanıcının belirli sınıfları temsil eden bir görüntüdeki örnek pikselleri seçebileceği ve ardından bu eğitim alanlarını görüntüdeki diğer tüm piksellerin sınıflandırılması için referans olarak kullanmak üzere görüntü işleme yazılımını yönlendirebileceği fikrine dayanır. Eğitim alanları kullanıcının bilgisine dayanılarak seçilir. Ayrıca kullanıcı benzer piksellerin nasıl gruplandırılması gerektiği konusunda sınırları da belirler. Bu sınırlar genellikle eğitim alanının spektral özelliklerine, artı veya eksi belli bir artışa (genellikle "parlaklık" veya spesifik spektral bantlardaki yansıma gücüne dayanarak) dayalı olarak ayarlanır. Kullanıcı ayrıca görüntünün sınıflandırıldığı sınıf sayısını da belirler (Şekil 2.22). Pek çok analist, son çıktı analizi ve sınıflandırılmış haritalar geliştirmek için kontrollü ve kontrolsüz sınıflandırma işlemlerinin bir kombinasyonunu kullanır.



Şekil 2.22. Kontrollü sınıflandırma yöntemiyle üretilmiş bir sınıflandırma haritası (Farooq, 2019)

Bu sınıflandırma yönteminde kullanılan birçok algoritma mevcuttur. Belli başlı algoritmalar aşağıda anlatılmıştır.

Maximum Likelihood – Maksimum Olabilirlik Yöntemi: Bu sınıflandırma algoritması her bir banttaki her bir sınıf için istatistiklerinin normal olarak dağıtıldığını ve belirlenmiş bir pikselin belli bir sınıfa ait olma olasılığını hesapladığını varsayar. Bir olasılık eşiği seçilmezse tüm pikseller sınıflandırılır. Her piksel, en yüksek olasılıklara sahip olan (yani, maksimum olasılık) sınıfa atanır. En yüksek olasılık belirtilen eşikten daha küçükse, piksel sınıflandırılmamış olarak kalır.

Görüntüdeki her piksel için (2.1) formülündeki ayırt edici işlevler hesaplanarak en yüksek olabilirlik sınıflandırması uygulanır (HarrisGeospatial, 2019).

$$g_i(x) = \ln p(\omega_i) - \frac{1}{2} \ln |\Sigma_i| - \frac{1}{2} (x - m_i)^T \Sigma_i^{-1} (x - m_i) \quad (2.1)$$

i = sınıf

x = n -boyutlu veri (n bant sayısı)

$p(\omega_i)$ = ω_i sınıfının görüntüde ortaya çıkma olasılığı ve tüm sınıflar için aynı olduğu varsayılır

$|\Sigma_i|$ = ω_i sınıfında verinin kovaryans matrisinin determinantı

Σ_i^{-1} = matrisin tersi

m_i = ortalama vektör


Support Vector Machine – Destek Vektör Makinesi (SVM) Yöntemi:

Genellikle karmaşık ve gürültülü verilerden iyi bir sınıflandırma sonucu veren istatistiksel öğrenme teorisinden türetilmiş bir kontrollü sınıflandırma yöntemidir. Sınıfları, sınıflar arasındaki marjı maksimize eden bir karar yüzeyi ile ayırır. Yüzeye genellikle en uygun hiper düzlem, hiper düzleme en yakın veri noktalarına destek vektörleri (support vector) denir. Destek vektörleri, eğitim setinin kritik unsurlarıdır. SVM doğrusal olmayan çekirdekleri kullanarak doğrusal olmayan bir sınıflandırıcı olacak şekilde uyarlanabilir. SVM, en basit haliyle bir ikili sınıflandırıcı olmasına rağmen, birkaç ikili SVM sınıflandırıcısını birleştirerek çok sınıflı bir sınıflandırıcı olarak işlev görebilir (her bir sınıf çifti için bir ikili sınıflandırıcı oluşturur) (HarrisGeospatial, 2019).

Minimum Distance – En Kısa Uzaklık Yöntemi: İşlemsel olarak basit olan bu yöntem özellikle eğitim veri sayısının az olduğu durumlar için uygundur. İlk adım olarak sınıf eğitim verilerinden her bir sınıf için ortalama değerler hesaplanır. Bilinmeyen pikseller bu uzaklıklara göre en yakın oldukları sınıflara atanır. Uzaklık ölçütü olarak Öklit ve Blok-Yuvarlama yöntemleri kullanılabilir (Sunar ve ark., 2011).

2.3.2. Nesne tabanlı sınıflandırma

Nesne tabanlı sınıflandırma, sadece görüntüdeki spektral bilgiyi değil piksellerin komşuluk özelliklerini yansıtan doku ve bağlam bilgilerini de kullanan bir yöntemdir (Şekil 2.23). Sınıflandırılan temel eleman piksel değil, komşuluk ilişkisine sahip piksel gruplarından oluşan nesnelerdir. Bireysel piksellerde görülemeyen semantik (anlamsal) bilgiler nesnelere ve nesnelere karşılıklı ilişkilerinde tespit edilebilir. Özellikle çok yüksek mekânsal çözünürlüklü uydu görüntülerinde yollar, binalar, park alanları, otlaklar gibi birçok cisim benzer spektral özellikler gösterirler. Buna bağlı olarak piksel tabanlı yaklaşım hem düşük doğruluklu hem de sınıf dağılımı düzensiz ve anlamlı olmayan sonuçlar üretebilir. Nesnelere genellikle otomatik segmentasyon algoritmalarıyla oluşturulur. Segmentasyon, ölçek, renk ve şekil gibi belirli homojenlik ölçütlerine göre piksellerin gruplanmasıdır. Nesnelere oluşturulduktan sonra, bu nesnelere ait istenen spektral, mekânsal, doku ve bağlamsal özellikler (komşuluk) çıkarılır. Nesne tabanlı sınıflandırmanın piksel tabanlı sınıflandırmadan olan bir diğer önemli farkı, çoğunlukla bulanık mantığa dayalı alt piksel sınıflandırma yaklaşımının kullanılmasıdır. Bulanık mantık yöntemi belirsiz olan birçok özelliğin sınıflandırma işlemine etkin olarak dahil edilmesini sağlar (Sunar ve ark., 2011). Piksel tabanlı sınıflandırmada olduğu gibi bu yöntemde de kontrollü ve kontrolsüz algoritmalar kullanılmaktadır.



Şekil 2.23. Piksel tabanlı ve nesne tabanlı sınıflandırma haritalarının şekilsel olarak karşılaştırması (Powell ve Brooks, 2019)

3. UYGULAMA

Bu çalışmanın temel amacı yeryüzündeki bitki örtüsü türlerinin uzaktan algılama yöntemleri ile sınıflandırılarak arazi kullanımına yönelik yüksek hassasiyet ve doğruluklu haritaların üretilmesidir. Bu amaçla Mersin ili Tarsus ilçesinde bulunan Alata Bahçe Kültürleri Araştırma Enstitüsü Müdürlüğüne ait arazi uygulama alanı olarak seçildi. Arazide ekili yonca ve soya bitkilerinin İHA platformuna entegreli multispektral kamera ile görüntüleri elde edildi. Multispektral görüntü işleme yazılımı Pix4D kullanılarak yeşil, kırmızı, kızıl-kenar ve kızılötesi bantlarda orto-görüntüler üretildi. Bu orto-görüntüler ArcGIS yazılımında işlenerek kontrolsüz ve kontrollü yöntemlerle sınıflandırma haritaları üretildi.

3.1. Donanım

Ekinlere ait görüntüler Parrot Bluegrass döner kanatlı İHA'ya entegreli Parrot Sequoia multispektral kamera ile elde edilmiştir (Şekil 3.1 ve 3.2).



Şekil 3.1. Parrot Bluegrass mikro-İHA

İHA'nın teknik özellikleri:

GENEL:

- Ağırlık: 1.81 kg
- Boyut: 30.48 cm x 40.64 cm in x 14 cm
- Taşıma için çıkarılabilir pervaneler

WI-FI VE SİNYAL İLETİMİ:

- Aralık: Parrot Skycontroller 2 km'ye kadar
- WiFi AC-type, 2 bi-band antenas (2,4 and 5GHz)

BATARYA KAPASİTESİ:

- Batarya süresi: 25 dakika
- 6700 mAh Lipo batarya

SENSÖRLER:

- Dâhili GPS + GLONASS
- Inertial Navigation System (INS)
- Altimetre
- Ultrason
- Optik akışlı dikey kamera

ÖN KAMERA:

- Fotoğraf: 14MP geniş açılı kamera
- Video: 1080p Full HD
- Video yayını: 360p / 720p
- Dâhili video belleği: 32GB



Şekil 3.2. Araca entegre edilen kamera sistemleri

Parrot Sequoia Multispektral Kamera özellikleri:

GENEL:

- Boyut: 2.3x1.6x1.1 in
- Ağırlık: 72 gr
- Fotoğraf modu: 1 fps'ye kadar
- Dâhili hafıza: 64 GB
- Inertial measurement unit & magnetometre
- Güç: 5 W (~12 W en son)

4 KÜRESEL ÖRTÜCÜLÜ TEK-BANT KAMERA:

- Çözünürlük: 1.2 Mpx, 1280x960 piksel
- HFOV: 61.9°
- VFOV: 48.5°
- DFOV: 73.7°

4 AYRI BANT:

- Yeşil: 550nm +/- 40nm
- Kırmızı: 660nm +/- 40nm
- Kırmızı Kenar: 735nm +/- 10nm
- Yakın Kızılötesi: 790nm +/- 40nm

RGB KAMERA:

- Çözünürlük: 16 MP, 4608x3456 piksel
- HFOV: 63.9°
- VFOV: 50.1°
- DFOV: 73.5°

GÜNEŞ IŞIĞI SENSÖRÜ:

- Boyutlar: 4.57x3.81x1.78 cm
- Ağırlık: 36 gr
- 4 spektral sensör (gövde ile aynı filtreler)
- GPS
- Inertial measurement unit & magnetometre
- SD Kart girişi
- Güç: 1 W




Şekil 3.3. Parrot Sequoia multispektral kamera

Parrot Sequoia multispektral kamera sistemi iki parçadan oluşmaktadır (Şekil 3.3). İlki dört farklı spektral bant ile RGB sensöre sahip olup eşzamanlı küresel deklanşör sistemiyle görüntüleri elde eden kamera, ikincisi ise kamera ile entegreli güneş ışığı sensörüdür. Bu sensör cihazın üstüne monte edilmiştir ve doğrudan güneşten gelen ışınlar ile mevcut aydınlatma koşullarını yakalayıp kaydını tutarak mutlak bir ölçüm için kamera çıktılarına otomatik olarak kalibre eder. Böylece kamera çıktıları olan multispektral görüntülerin doğruluğu yüksek radyometrik çözünürlükte olmasını sağlar.

3.2. Çalışma Alanı

Çalışma alanı Mersin ili Tarsus ilçesinde (Şekil 3.4) bulunan Alata Bahçe Kültürleri Araştırma Enstitüsü Müdürlüğüne ait arazide yapılmıştır (Şekil 3.5). Arazide ekili olan soya ve yonca bitkilerinin multispektral görüntüler vasıtasıyla ayırt edilmesi amaçlanmıştır.



Şekil 3.4. Mersin ilçe haritası



Şekil 3.5. Alata Bahçe Kùltürleri Arařtırma Enstitüsü Tarsus Mùdùrlùğü arazisi

Bitki türlerinin sınıflandırılması amacıyla başladığımız çalışmamıza iki farklı bitki türünün, yonca ve soya bitkilerinin, ekildiği 4.5 hektarlık alanda çalışma yapıldı (Şekil 3.6).



(a)


(b)

Şekil 3.6. Arazideki soya (a) ve yonca (b) ekinleri


3.3. Arazi Çalışması

Ekinlere ait görüntüler fotogrametri yöntemiyle elde edilip işlendi. Bu çalışmada uygulanan yöntemde İHA için gereken uçuş planı, Pix4D firması tarafından sağlanan uçuş planlayıcı mobil uygulaması ile oluşturuldu. Uçuş, belirlenen çalışma alanı içinde %80 boyuna ve enine bindirme oranında, yer örnekleme aralığı (YÖA/GSD) yaklaşık 7 cm olacak şekilde gerçekleştirildi. Bunun yanında uçuşun güneş ışınlarının en yüksek yansıma seviyesine sahip olduğu öğle saatinde yapılmasına dikkat edildi. Uçuşa başlamadan önce ortamın güneş ışığı yansıma değerlerinin belirlenip görüntülerin


kalibre edilmesi için spektral kalibrasyon kağıdının görüntüleri multispektral kamera ile edinildi (Şekil 3.7).




(a)



(b)



(c)



(d)


Şekil 3.7. Spektral kalibrasyon kâğıdının görüntüsünün İHA'ya monteli multispektral kamera ile alınması. a) yeşil b) yakın kızıl ötesi c) kırmızı d) kırmızı-kenar görüntüler

Saat 11.30'da uçuşa başlayan İHA seyrini yaklaşık 5 dakika sürdürmüş olup ortalama 4.7 hektarlık alanın multispektral görüntülerini başarılı bir şekilde edindi. Bu uçuş sonucunda toplamda 1665 adet görüntü elde edilmiştir. Yeşil, kırmızı, kırmızı-kenar, yakın kızıl ötesi ve RGB bantlarının her birinden 333 tane görüntü toplanmıştır.

3.4. Görüntülerin İşlenmesi ve Değerlendirilmesi

Bu görüntülerden RGB hariç diğer banttaki görüntüler (yeşil, kırmızı, kırmızı-kenar, yakın kızıl ötesi) işlenmek üzere Pix4D yazılımına aktarıldı. Pix4D yazılımı, Structure from Motion (SfM) algoritması ile çalışmakta ve görüntüleri ışın demetleriyle blok dengeleme yaparak işlemektedir. Bu çalışmada yazılımın multispektral görüntüleri işleme için tarım uygulamalarına yönelik modülü kullanıldı. Kalibrasyon kağıtlarının görüntüleri yazılıma tanıtılarak spektral kalibrasyon yapıldıktan sonra görüntüler yöneltme işlemine tabi tutulup arazi yüzeyinin 3B modelinin tahmini şekli seyrek nokta bulutu ile oluşturuldu. Akabinde yoğun nokta bulutu oluşturulup üzerinden yüzey geçirilmiştir. Sonrasında ise her bir bant için ayrı ayrı 7.81 cm yer örnekleme aralığına sahip ortofoto üretildi. Ortofotolar ESRI ArcGIS yazılımında işlenmek üzere .tif biçiminde dışarı çıkarıldı.

Her bir bant ArcGIS yazılımının içine aktarıldı ve sınıflandırma çalışmalarına altlık olmak üzere birleştirilerek kompozit görüntü elde edildi. Yeşil, kırmızı, kırmızı-kenar ve yakın kızıl ötesi bantları ihtiva eden kompozit görüntü ArcToolbox modülü ile üretildi (Şekil 3.8).



Şekil 3.8. 4 bandın birleştirilmesiyle oluşan kompozit false color görüntü

Çalışmada 1 adet kontrolsüz ve 2 adet kontrollü sınıflandırma yapılarak doğruluk analizi yapıldı. Sınıflandırma çalışmaları aşağıdaki başlıklar altında gerçekleştirildi.


- a) Kontrolsüz Sınıflandırma
 - i) ISO data cluster
- b) Kontrollü Sınıflandırma
 - i) Maximum Likelihood
 - ii) Support Vector Machine

Görüntü işleme adımları aşağıdaki başlıklar altında detaylı olarak anlatılmaktadır.

3.4.1. Pix4D


Pix4D yazılımı, SfM algoritması ile çalışmakta ve görüntüleri ışın demetleriyle blok dengeleme yaparak işlemektedir. RGB, termal ve multispektral görüntüleri haritalara ve 3B modele dönüştürmek için fotogrametri ve bilgisayarlı görüntü algoritmaları kullanan bir dizi paket yazılım ürünüdür. Arazide kullanmış olduğumuz Sequoia multispektral kamera görüntülerinden ortomozaik üretmek için kullanıldı.

Kalibrasyon kartlarının görüntüleri de dâhil arazide elde edilen tüm görüntüler programa aktarıldıktan sonra Ag Multispectral işleme modülü seçilmiştir (Şekil 3.9).



Şekil 3.9. Pix4D yazılımında kullanılan modüllerin seçim penceresi

Proje dosyası oluşturulduktan sonra kameraların radyometrik kalibrasyonları yapılmıştır (Şekil 3.10).



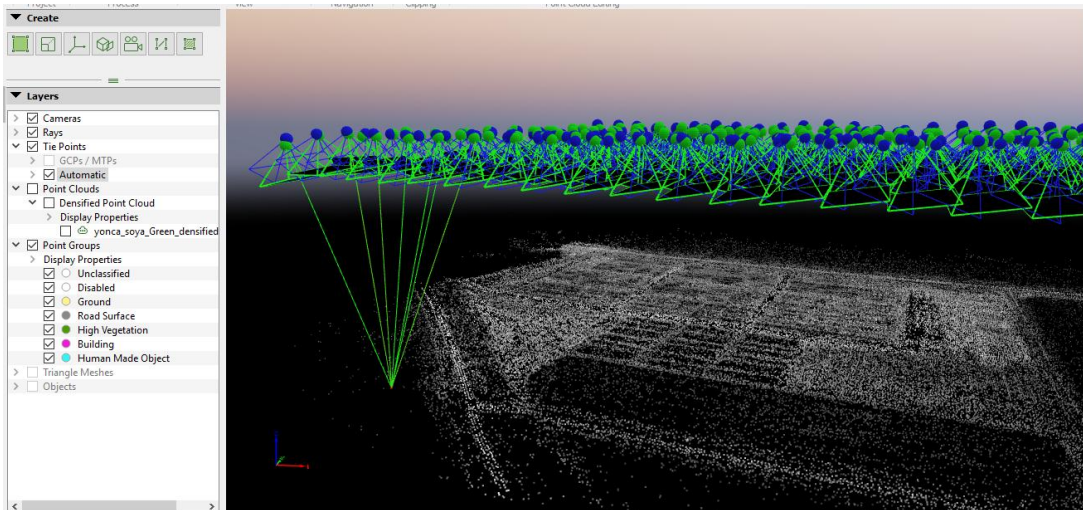
Şekil 3.10. Radyometrik kalibrasyon işlem penceresi

Şekil 3.11'deki pencerede her bir bant için tek tek yapılmak üzere "Calibrate..." tıklanmış ve açılan pencerede radyometrik kalibrasyon kağıtlarının görüntüleri üzerindeki radyometrik kalibrasyon alanı çizilerek işaretlenmiştir.




Şekil 3.11. Radyometrik kalibrasyon alanının seçilmesi

Bu ayarlar her bir bant için uygulandıktan sonra işlem başlatıldı ve SfM algoritması ile birincil işlem sonucunda bağ noktaları üretildi (Şekil 3.12). Bağ noktaları ile fotoğraflar dengelendi ve bu fotoğraflar üzerinden yoğun nokta bulutu elde edildi (Şekil 3.13).



Şekil 3.12. Bağ noktalarının teşkil ettiği seyrek nokta bulutu



Şekil 3.13. Yoğun nokta bulutu

Son olarak DSM, ortomozaik ve indeks işlemleri gerçekleştirilmiştir. Bu işlem sonucunda yeşil, kırmızı, kızıl-kenar ve kızıl ötesi bantlarında ortomozaikler oluşturulmuştur (Şekil 3.14, 3.15, 3.16 ve 3.17).



Şekil 3.14. Ekin arazisine ait kızıl ötesi bandındaki ortomozaik




Şekil 3.15. Ekin arazisine ait yeşil banttaki ortomozaik



Şekil 3.16. Ekin arazisine ait kırmızı banttaki ortomozaik



Şekil 3.17. Ekin arazisine ait kızıl-kenar banttaki ortomozaik



Şekil 3.18. Ekin arazisine ait NDVI görüntüsü

Canlı bitkilerin arazideki varlığı ve sağlığı hakkında bilgi veren Normalize Fark Bitki Örtüsü Endeksi – Normalized Difference Vegetation Index (NDVI) görüntüsü oluşturuldu (Şekil 3.18). Yukarıdaki şekillerde görülen ortomozaikler .tiff biçiminde ArcGIS yazılımında işlenmek ve analiz edilmek üzere dışarı aktarılmıştır.


3.4.2. ArcGIS

ArcGIS teknolojisi, ESRI tarafından geliştirilmiş, ölçeklendirilebilir bütünleşik bir Coğrafi Bilgi Sistemi yazılımıdır. Yazılım bileşenlerinin ortak kütüphanesi ArcObjects üzerine kurulmuş bir sistemdir. CBS yazılım bileşenlerinin ortak kütüphanesi ArcObjects üzerine kurulmuş bir sistemdir. ArcGIS teknolojisi aşağıdaki anahtar bölümleri içerir.


- Desktop GIS: İleri düzeyde CBS uygulamalarının bütünüdür.
- Mobile GIS: Ofis dışında arazide CBS uygulamalarını gerçekleştirmenizi sağlar.
- Server GIS: Ortak CBS yazılım objeleri kütüphanesidir. Sunucu tarafında bütün CBS uygulamalarını, SOAP tabanlı web servislerini ve web uygulamalarını gerçekleştirmek için kullanılır.
- Online GIS: İsteğe bağlı olarak güncel CBS verilerine ve yeteneklerine düşük maliyetlerle erişmenizi sağlayan servislerdir. Bütün bu sistemler aynı zamanda, coğrafi bilgilerin birçok ilişkisel veri tabanı yönetim sistemi (İVTYS) içerisinde yönetilebilmesini de ArcSDE teknolojisi ile sağlar.

ArcGIS, desktop ve sunucu tarafında, tek veya çok kullanıcı ortamlarda Coğrafi Bilgi Sistemi uygulamaları için ölçeklendirilebilir bir altyapı sağlar.

ArcGIS çalışmalarında ilk işlem adımı olarak veritabanı yapısı oluşturulur. Çalışmamızda ArcCatalog yazılımı kullanılarak veritabanı oluşturuldu. Çalışmada kullanılacak bütün vektör ve raster veriler bu veritabanının içerisinde konumlandırıldı. Projenin bilgisayar içerisinde çalışılacak ve depolanacak alanını belirlemek için Connect to Folder tıklanarak klasör yolu belirlendi (Şekil 3.19).




Şekil 3.19. ArcCatalog yazılımı ile çalışılacak klasörün konumunun ayarlanması



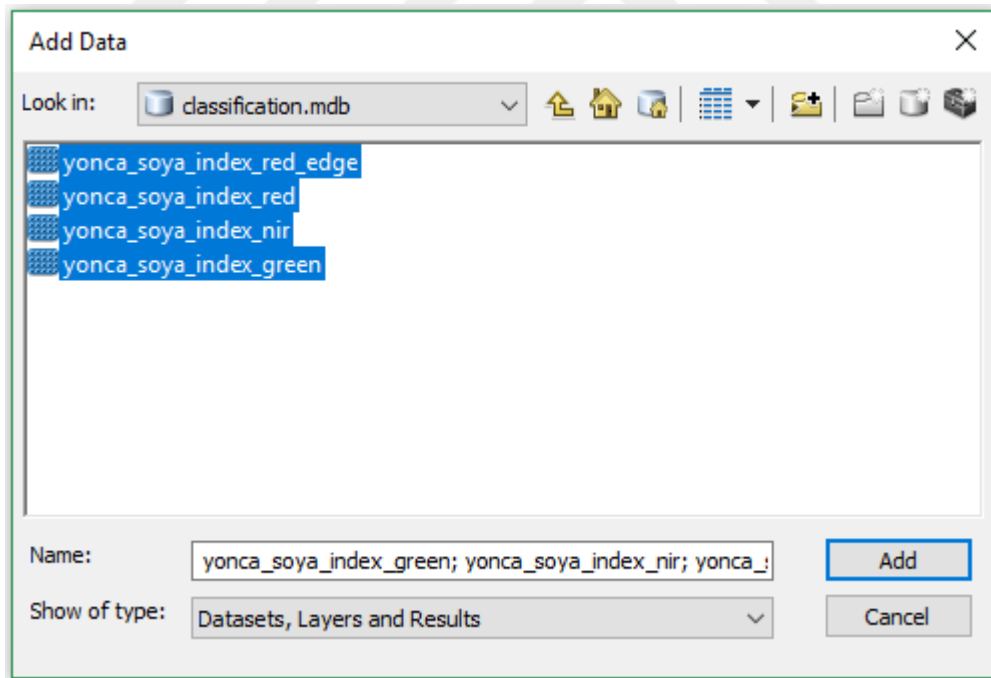
Şekil 3.20. Veri tabanının oluşturulması

Açılan klasörün içine Personal Geodatabase biçiminde veritabanı dosyası oluşturuldu (Şekil 3.20). Veritabanı içerisine Pix4D yazılımında üretilen ortofoto bantlar aktarıldı (Şekil 3.21).



Şekil 3.21. Ortofoto bantların veritabanına aktarılması


Bu aşamadan sonra raster dosyalar ArcMap yazılımına işlenmek üzere aktarıldı (Şekil 3.22).




Şekil 3.22. Raster dosyalarının ArcMap yazılımına aktarılması

Yeşil, kırmızı, kızıl-kenar ve kızılötesi bantlarındaki görüntüler bu aşamada birbirinden bağımsız olarak farklı katmanlarda yer almaktadır. Multispektral görüntülerin sınıflandırma işlemine tabi tutulması için birleştirilerek kompozit bir

görüntü haline getirilmesi gerekmektedir. Bu amaçla *ArcToolbox* araç kutusundaki *Data Management Tools > Raster > Raster Processing > Composite Bands* yoluyla bantları birleştirme aracı kullanılarak kompozit görüntü üretildi (Şekil 3.23 ve 3.24).



Şekil 3.23. Kompozit görüntünün ArcToolbox araçları ile oluşturulması



Şekil 3.24. Oluşturulan kompozit RGB görüntü


3.4.3. Kontrolsüz Sınıflandırma Çalışmaları

Kontrolsüz sınıflandırma; piksellerin, kullanıcı müdahalesi olmadan otomatik olarak kümelendirilmesi temeline dayanmaktadır. Bu çalışmada kontrolsüz sınıflandırma yöntemlerinden ISO data cluster kullanılmıştır.

3.4.3.1. ISO Data Cluster

ISO cluster algoritması, her aday hücreyi bir kümeye atarken minimum Öklid mesafesini hesaplamak için kullanılan iteratif bir işlemdir. Süreç, her küme için bir tane olmak üzere, yazılım tarafından atanan keyfi değerlerle başlar (tarafımızdan girilen küme sayısı ile). Her hücre, bu değerlerin en yakınına atanır. İlk iterasyondan sonra kümeye ait olan hücrelerin öznitelik mesafelerine bağlı olarak her küme için yeni değerler yeniden hesaplanır.


Çalışma alanında 4 adet sınıf belirlenmiş olup bunlar soya, yonca, toprak ve yabancı ot olarak ayrılmıştır. Ancak kontrolsüz sınıflandırmada eğitim bölgeleri işaretlenmediğinden programa 5 tane sınıflandırma yapması komut verilmiştir. İşlem sonucu oluşan sınıflandırma haritası aşağıdadır (Şekil 3.25).



Şekil 3.25. ISO cluster sınıflandırma

Kontrolsüz sınıflandırma için ArcMap yazılımında oluşturulan kompozit görüntü işleme sokulmuştur. *Image Classification* araç çubuğunda *Classification* tıklandıktan

sonra *Iso Cluster Unsupervised Classification* seçildi. Açılan pencerede altlık görüntü, sınıf sayısı ve dosya konumları girildikten sonra sınıflandırma haritası otomatik olarak oluşturuldu (Şekil 3.26).



Şekil 3.26. Iso Cluster Kontrolsüz Sınıflandırma oluşturma penceresi


Bu sınıflandırma haritasının (Şekil 3.25) doğruluğunun çok düşük olduğu açık bir şekilde görülmektedir. Eğitimsiz sınıflandırmanın bu çalışma için başarısız olduğu sonucuna varılmıştır.

3.4.4. Kontrollü Sınıflandırma Çalışmaları

Kontrollü sınıflandırmada görüntünün hangi sınıflara ayrılacağı, ya da görüntüden hangi sınıfların elde edilmek istenildiği önceden bilinir. Bunun için görüntüden belirlenen sınıflara ait denetim alanlarının seçilmesi gerekmektedir. Bu seçim için gerektiğinde arazide yer gerçekliği yapılması zorunludur. Kontrol alanlarının seçimi sınıflandırmanın doğruluğunu etkileyen bir aşamadır.


3.4.4.1. Maximum Likelihood

Bu sınıflandırma algoritması her banttaki her bir sınıf için istatistiklerinin normal olarak dağıtıldığını ve belirlenmiş bir pikselin belli bir sınıfa ait olma olasılığını hesaplar. Kompozit görüntü üzerinde niteliği bilinen alanlar algoritmaya tanıtılarak eğitildi (Şekil 3.27).



Şekil 3.27. Eğitim alanları


Bu eğitimli alanlara ait pikseller sayesinde diğer tüm piksellerin sınıfı tahmin edildi. Belirlenen 4 adet sınıf için eğitilen alanlar baz alınarak sınıflandırma haritası oluşturuldu. ArcGIS yazılımında Arctoolbox modülü ile oluşturulan sınıflandırma haritası Şekil 3.28'deki gibidir.



Şekil 3.28. Maximum Likelihood sınıflandırma

3.4.4.2. Support Vector Machine

Support Vector Machine (SVM), genellikle karmaşık ve gürültülü verilerden iyi bir sınıflandırma sonucu veren istatistiksel öğrenme teorisinden türetilmiş bir kontrollü sınıflandırma yöntemidir. Bu yöntemde de maximum likelihood yönteminde kullanılan eğitim alanları kullanıldı (Şekil 3.27). Söz konusu eğitim alanları arazi gerçeğinde niteliği bilinen ve görüntüde açıkça belirli olan kısımlardan çizildi. Bu yöntem ile oluşturulan sınıflandırma haritası Şekil 3.29'da verilmiştir.



Şekil 3.29. Support Vector Machine sınıflandırma haritası

4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Bu çalışma sonucunda soya ve yonca ekinlerine ait multispektral görüntüler elde edilmiş ve bu iki bitki türü sınıflandırılmıştır. Sınıflandırma çalışmalarının doğruluğunu kontrol etmek için doğruluk değerlendirmesi yapılmıştır. Doğruluk değerlendirmesi, uzaktan algılamada, görüntü sınıflandırmasında bir piksele atanan sınıf etiketi ile gerçek değer arasındaki uygunluğun ortaya konmasıdır. Gerçek sınıf, arazide bulunan nesnelerin hava fotoğraflarından ya da mevcut harita ve planlardan doğrudan veya dolaylı olarak gözlenebilir. Gerçek sınıf arazi çalışması esnasında yapılan gözlemler yardımıyla doğrudan görüntü üzerinden belirlenmiştir.

Doğruluk değerlendirmesinde kullanılmak üzere sınıflandırılmış görüntü üzerine örneklem noktaları atılması gerekmektedir. Örneklem noktalarının adedi görüntünün toplam piksel sayısına göre hesaplanarak, en az 289 adet nokta gerektiği tespit edilmiştir. Bu çalışmada kullanılan örneklem noktalarının sayısı formül (4.1) kullanılarak tespit edilmiştir.

$$n = \frac{N \cdot t^2 \cdot p \cdot q}{d^2 \cdot (N - 1) + t^2 \cdot p \cdot q} \quad (4.1)$$

N: Evren sayısı [7,418,751 piksel] (Ortofotodaki tüm piksellerin sayısı)

n: Örneklem sayısı

p: İncelenen olayın görülme sıklığı (olasılığı) [4 tane sınıf olduğundan bir pikselin doğru değer olma olasılığı 0.25'tir.]

q: İncelenen olayın görülmeme sıklığı (olasılığı) [0.75]

t: Belirli serbestlik derecesinde ve saptanan yanılma düzeyinde t tablosunda bulunan teorik değer [1.96]

d: Olayın görülme sıklığına göre yapılmak istenen \pm sapma [%95 güven aralığında 0.05'tir]

(4.1) formülü hesaplandığı zaman n=288.12 olup örneklem sayısı en az 289 olarak bulunmuştur. Bu hesaplama toplamda 300 adet nokta görüntü üzerine otomatik olarak rastgele atıldı. Bu işlem ArcGIS yazılımının ArcToolbox modülü ile gerçekleştirildi. Bu modül sayesinde noktaların altlık olarak kullanılan sınıflandırma haritalarında denk geldiği piksel değeri otomatik olarak öznelik tablosuna

aktarılmıştır. Yer gerçekliği ise kompozit görüntü üzerinden öznitelik tablosuna el ile girildi. Yer gerçekliğinin tabloya girilmesinde görüntüden faydalandığı kadar arazide iken yapılan gözlemlerden de faydalanılmıştır. Her bir sınıf numaralandırılmış olup sırasıyla 1=soya, 2=yonca, 3=toprak ve 4=yabani ot olarak kodlandı. Örneklem noktalarının konumu aynı kalacak şekilde her bir sınıf için farklı öznitelik tablosu oluşturuldu. Öznitelik tabloları ile hata matrisleri oluşturuldu.

Maximum Likelihood sınıflandırma için oluşturulan hata matrisi Çizelge 4.1’de olduğu gibidir.

Çizelge 4.1. Test alanına ilişkin Maximum Likelihood sınıflandırma performansı; Hata Matrisi

Sınıf	Soya	Yonca	Toprak	Yabani Ot	Toplam	Kullanıcı Doğruluğu	Kappa
Soya	84	2	0	11	97	0.87	
Yonca	0	14	0	0	14	1.00	
Toprak	1	0	121	4	126	0.96	
Yabani Ot	18	0	3	42	63	0.67	
Toplam	103	16	124	57	300	0.00	
Üretici Doğruluğu	0.82	0.88	0.98	0.74	0	0.87	
Kappa							0.81

Soya, yonca, toprak ve yabani ot sınıflarının üretici doğruluğu ve kullanıcı doğruluğunun karşılaştırması Tablo 1’de verilmiş olup genel doğruluk %87 olarak hesaplanmıştır. Kappa değeri ise 0.81 olarak hesaplanmış olup;

- 1.00 tam uyum olduğunu,
- 0.75 ve fazlası sınıflandırma performansının çok iyi olduğunu,
- 0.40’ ın aşağısı ise performansın yetersiz olduğunu,
- 0.00 ise sınıflandırılmış ve referans verileri arasında uyumun olmadığını gösterir.

Bu durumda Maximum Likelihood sınıflandırma işleminin performansının çok iyi olduğu söylenebilir.

Support Vector Machine sınıflandırma işlemi için oluşturulan hata matrisi Çizelge 4.2’de olduğu gibidir.

Çizelge 4.2. Test alanına ilişkin Support Vector Machine sınıflandırma performansı; Hata Matrisi

Sınıf	Soya	Yonca	Toprak	Yabani Ot	Toplam	Kullanıcı Doğruluğu	Kappa
Soya	77	0	0	8	85	0.91	0
Yonca	1	12	0	0	13	0.92	0
Toprak	2	0	123	18	143	0.86	0
Yabani Ot	23	4	1	31	59	0.53	0
Toplam	103	16	124	57	300	0	0
Üretici Doğruluğu	0.75	0.75	0.99	0.54	0	0.81	0
Kappa	0	0	0	0	0	0	0.71

Support Vector Machine sınıflandırma performansına ilişkin hata matrisindeki genel doğruluk %81 olup kappa değeri %71 olarak hesaplanmıştır. Buna göre sınıflandırmanın iyi bir performans sergilediği söylenebilir.


Sınıflandırmanın doğruluğunu değerlendirmek için ayrıca yeniden sınıflandırma (reclassification) işlemi yapılmıştır. Bu işlemler de ArcGIS programı ile her iki sınıflandırma görüntüsü (Maximum Likelihood ve Support Vector Machine) kullanılarak ayrı ayrı yapılmıştır. Yeniden sınıflandırma işleminde her bir sınıfa ait piksel sayıları hesaplandı. Bu pikseller yer örnekleme aralığının alan değerine çarpılarak her bir sınıfın kapladığı alan hesaplandı. Bunun sonucunda ortaya çıkan değerler Çizelge 4.3'te verildiği gibidir.

Tablo 4.3. Arazi sınıflarının kapladığı piksel sayısı ve yüzölçümü

Sınıf	Maximum Likelihood		Support Vector Machine	
	Piksel Sayısı	Alan (m ²)	Piksel Sayısı	Alan (m ²)
Soya	2447467	14928.59	1843538	11244.86
Yonca	351619	2144.74	383280	2337.86
Toprak	3353034	20452.20	3687499	22492.31
Yabani Ot	1731812	10563.38	1969615	12013.88


Soya ve yonca ekin alanlara ait sayısallaştırma işlemi çalışmada üretilen ortofoto kullanılarak yapılmış ve yüzölçümleri hesaplanmıştır (Şekil 4.1). Elde edilen sayısallaştırma sonucunda alanın 16001.65 m²'sinde soya, 2446.02 m²'sinde yonca olduğu tespit edilmiştir. Sayısallaştırma sonuçları ve çalışmada tercih edilen sınıflandırma sonuçları karşılaştırıldığında soya için en yakın değer Maximum Likelihood yönteminde görülmektedir. Yonca için en yakın değer ise Support Vector Machine yönteminde hesaplanmıştır. Ancak sayısallaştırma yapılırken Şekil 4.1'de (a) ile gösterilen alanda ekimin planlandığı alanlar göz önünde bulundurulmuş olup ekinin

bittiği alan göz ardı edilmiştir (Şekil 4.3). Soya için en yakın değerin Maximum Likelihood yönteminde çıkması doğrudan buna bağlıdır.




Şekil 4.1. Yonca ve soya ekin alanları a) soya, b) yonca c) soya

Çalışmanın odak noktası olan soya ve yonca ekinlerinin kapladığı alanın yüzölçümü hesaplanmıştır. Yabani ot alanlarının yüzölçümü bunlara nispeten dağınık halde bulunduğundan hesaplanmamıştır. Buna bağlı olarak toprak alanının yüzölçümü de hesap dışında kalmıştır. Sadece soya ve yonca alanlarının kullanılması bile doğruluk değerlendirmesi için yeterli görünmektedir. Tez çalışmasının konusu olan sınıflandırma açısından yüksek doğruluklu sonuçlar elde edilmiş olması bu yöntemin başarısını göstermektedir (Tablo 4.1 ve 4.2).



Şekil 4.2. Sınıfların arazide kapladığı alanların karşılaştırması

Şekil 4.1’de (a) ile gösterilen soya ekili alanda ürünün yetiştirilmek istendiği alan görülmektedir. Ancak gerçekte ürün bu alanların tamamını kaplamamakta olup yer yer varlık göstermektedir (Şekil 4.3). Şekil 4.2’de verilen grafikte farklı yöntemlerle üretilen her bir sınıfın arazide kapladığı yüzölçüm miktarı görülmektedir.



Şekil 4.3. Taralı alan dikim alanlarını, kırmızı alanlar ise soyanın bittiği alanları göstermektedir.

Çalışmada karşımıza çıkan bu sonuç bitki türlerinin ayırt edilmesi ve sınıflandırılmasının yanında rekolte tahmini ve ekinlerin takip edilmesinde kolaylık sağlayacağını göstermektedir. Bir arazinin kaçta kaçının kullanıldığı hesaplanarak verimlilik analizleri yapmak mümkündür. Hektarlarca genişlikteki alanlardaki bitki

büyüme, gelişme ve sağlık takibinde İHA'ların yüksek doğruluklu mekânsal ve zamansal verileri elde etmedeki başarısı ortaya konmuştur.

Kontrollü sınıflandırma yönteminde elde edilen yüksek başarı oranı sınıflandırma çalışmalarındaki kullanılabilirliğini gözler önüne sermektedir. Bitki türlerinin ayırt edilmesinde kızılötesi ve kızıl-kenar bandın etkili olduğu birçok çalışmada belirtilmiş olup bu çalışmada da önemli rol oynamıştır (Schmidt ve Skidmore, 2003; Artigas ve Yang, 2006; Arafat ve ark., 2013). İHA'lar sağladığı yüksek mekânsal çözünürlük sayesinde ekili alanlardaki bitki türlerinin sınıflandırılmasında etkili kullanım olanağına sahiptir. Arazi kullanımına yönelik daha detaylı bilgilerin elde edilmesinde İHA ve İHA'ya monte edilmiş multispektral kamera sistemlerinin kullanımı ile verimli sonuçlar ortaya konmuştur.



5. SONUÇLAR VE ÖNERİLER

Tarım, insanlığın yeryüzünde varoluşundan beri var olan, temel olarak insanların beslenmesi amacıyla ekonomik değeri olan her türlü bitkisel ürününün bakım, yetiştirme, koruma ve mekanizasyon faaliyetlerinin tümüdür. Tarım teknolojisi tarih boyunca gelişen teknolojiye bağlı olarak sürekli değişim göstermiştir. Günümüzde dünyada geleneksel tarım uygulanan yerler olduğu kadar gelişmiş mekanize tarım tekniklerinin uygulandığı yerler de mevcuttur. Gelişmiş ülkelerde modern tarım teknolojisi yaygın olarak uygulanmaktadır. Gelişmekte olan ülkelerde ise geleneksel tarımdan modern tarıma geçişin olduğu görülmektedir. Gelişmekte olan ülkeler arasında yer alan ülkemizde de modern tarım teknolojisine geçiş faaliyetlerinde bulunmaktadır. Tarımcılığa yönelik devlet desteklerinin sağlanması ve modern teknolojiyi kullanan çiftçi sayısının artması için imkân oluşturulması bir devlet politikası haline gelmiştir. Ülkemizin sahip olduğu ve tarihte bilinen ilk tarımın yapıldığı bereketli Anadolu topraklarında modern tarım uygulamaları ile ülke ekonomisine katma değer yaratılması amaçlanmaktadır. Bu amaçla dünyada geliştirilen teknolojilerin bir an önce ülkemize kazandırılması ve uygulanabilir hale getirilmesi gerekmektedir.

Son on yılda İHA teknolojisinin gelişmesi ile kullanımı birçok sivil uygulama alanında yaygınlaştığı gibi tarım faaliyetlerinde de yaygınlaşmıştır. İlaçlama, arazi kullanımı tespiti, kuraklık zararı tespiti, bitki sağlığının izlenmesi gibi birçok tarımsal faaliyetlerde kullanımı söz konusudur. İHA'lara monte edilen multispektral kameralar ile arazi kullanımı ve bitki örtüsü türlerinin tespiti mümkün olmaktadır.

Bu çalışmada bitki türünün tespit edilerek haritada gösterilmesi amacıyla yonca ve soya bitkilerinin ekildiği araziden multispektral görüntüler elde edildi. Görüntüler çeşitli yazılımlarda işlenerek Maximum Likelihood, Support Vector Machine ve ISO-data kümeleme yöntemi olmak üzere üç farklı algoritma ile sınıflandırıldı. Bu sınıflandırma çalışmalarının doğruluğu incelendi. Yapılan sınıflandırmalarda aynı eğitim bölgeleri ve örneklem noktaları kullanıldı. Sınıflandırmalar sonucu Maximum Likelihood için doğruluk %87 ve kappa %81, Support Vector Machine için ise doğruluk %81 ve kappa %71 olarak hesaplandı. Bu istatistiki bilgilere göre çalışmamız için en iyi sonucu veren sınıflandırma algoritmasının Maximum Likelihood olduğu ortaya çıkmıştır. Kontrolsüz sınıflandırma yönteminin kontrollü sınıflandırma yöntemlerine göre başarısız olduğu tecrübe edilmiştir. Yüksek konum hassasiyeti istenen çalışmalarda kontrollü sınıflandırma yönteminin kullanılması tavsiye edilmektedir. Arazi

kullanımının daha detaylı analiz edilebilmesi ve ekim alanlarındaki bitki türlerinin daha detaylı tespit edilebilmesi için İHA kullanımının oldukça pratik ve etkili olduğu görülmüştür. İHA'ların esnek kullanım olanağına sahip olması ve maliyet bakımından erişilebilir olması tarım çalışmaları için kullanılabilirliğini ön plana çıkarmaktadır. 5 hektar alanda ortalama 7 cm yer örnekleme aralıklı ortomozaik elde etmek için 5 dakikalık bir uçuş gerçekleştirilmiştir. Bu durum İHA'ların geniş alanlarda yüksek konum doğruluğu ve hassasiyetine sahip verileri kısa sürede elde edebileceğini kanıtlamaktadır.

Arazide bitki üzerine düşen gölgeli alanların sınıflandırılmasında yer yer hatalar görülmüştür. Güneşten yansıyan ışığın doğrudan algılanamamasından kaynaklanan bu hatalar özellikle ekinlerin çevrelerinde oluşmuştur. Bu sebeple ekinlerin çevresi yabancı ot sınıfında gösterilmiştir. Ancak doğruluk araştırması sonuçlarına göre çalışmamızda oluşan hatalar tolerans sınırları içerisinde kalmaktadır. Bu tür hataların nasıl giderileceği ileriki çalışmalar için bir araştırma konusu teşkil edebilir.

KAYNAKLAR

- Adam, E. ve Mutanga, O., 2009, Spectral discrimination of papyrus vegetation (Cyperus papyrus L.) in swamp wetlands using field spectrometry, *ISPRS Journal of Photogrammetry and Remote Sensing*, 64 (6), 612-620.
- Ahmad, A., Tahar, K. N., Udin, W. S., Hashim, K. A., Darwin, N., Hafis, M., Room, M., Hamid, N. F. A., Azhar, N. A. M. ve Azmi, S. M., 2013, Digital aerial imagery of unmanned aerial vehicle for various applications, *Control System, Computing and Engineering (ICCSCE), 2013 IEEE International Conference on*, 535-540.
- Akyürek, S., Yılmaz, M. A. ve Taşkiran, M., 2012, İnsansız Hava Araçları: Muhabere Alanında ve Terörle Mücadelede Devrimsel Dönüşüm, *Bilge Adamlar Stratejik Araştırma Merkezi, Ankara*.
- Altunkaya, Z. ve Yastıklı, N., 2011, Ortogörüntüler Yardımıyla Nene Tabanlı Sınıflandırma Yöntemi Kullanılarak Öznitelik Çıkarımı. TMMOB Coğrafi Bilgi Sistemleri Kongresi 2011. Antalya, HKMO.
- Anchang, J. Y., Ananga, E. O. ve Pu, R., 2016, An efficient unsupervised index based approach for mapping urban vegetation from IKONOS imagery, *International Journal of Applied Earth Observation and Geoinformation*, 50, 211-220.
- Anderson, K. ve Gaston, K. J., 2013, Lightweight unmanned aerial vehicles will revolutionize spatial ecology, *Frontiers in Ecology and the Environment*, 11 (3), 138-146.
- Arafat, S. M., Aboelghar, M. A. ve Ahmed, E. F., 2013, Crop discrimination using field hyper spectral remotely sensed data, *Advances in Remote Sensing*, 2 (02), 63.
- Artigas, F. J. ve Yang, J., 2006, Spectral discrimination of marsh vegetation types in the New Jersey Meadowlands, USA, *Wetlands*, 26 (1), 271.
- Austin, R., 2010, Unmanned aircraft systems: UAVS design, development and deployment, *United Kingdom, John Wiley & Sons Ltd*, p.
- Barrero, O. ve Perdomo, S. A., 2018, RGB and multispectral UAV image fusion for Gramineae weed detection in rice fields, *Precision Agriculture*, 19 (5), 809-822.
- Bhola, R., Krishna, N. H., Ramesh, K. N., Senthilnath, J. ve Anand, G., 2018, Detection of the power lines in UAV remote sensed images using spectral-spatial methods, *Journal of Environmental Management*, 206, 1233-1242.
- Calderón, R., Montes-Borrego, M., Landa, B. B., Navas-Cortés, J. A. ve Zarco-Tejada, P. J., 2014, Detection of downy mildew of opium poppy using high-resolution multi-spectral and thermal imagery acquired with an unmanned aerial vehicle, *Precision Agriculture*, 15, 639-661.
- Dudley, K. L., Dennison, P. E., Roth, K. L., Roberts, D. A. ve Coates, A. R., 2015, A multi-temporal spectral library approach for mapping vegetation species across spatial and temporal phenological gradients, *Remote Sensing of Environment*, 167, 121-134.
- Eisenbeiß, H., 2009, UAV photogrammetry, *ETH Zurich*.
- Eroğlu, O., 2013, İnsansız Hava Araçlarında Arazi Verilerine Dayalı Uçuş Yönü Sınırlamasız Konumlandırma Sistemi Benzetim Çalışması, Yüksek Lisans Tezi.
- Everaerts, J., 2008, The use of unmanned aerial vehicles (UAVs) for remote sensing and mapping, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 37 (2008), 1187-1192.
- Farooq, S., 2019, Supervised Classification, Hindistan, <http://www.geol-amu.org/notes/m14a-4-9.htm>: [14 Haziran 2019].

- Fassnacht, F. E., Latifi, H., Stereńczak, K., Modzelewska, A., Lefsky, M., Waser, L. T., Straub, C. ve Ghosh, A., 2016, Review of studies on tree species classification from remotely sensed data, *Remote Sensing of Environment*, 186, 64-87.
- Gini, R., Passoni, D., Pinto, L. ve Sona, G., 2012, Aerial images from an UAV system: 3D modeling and tree species classification in a park area, *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 39 (B1), 361-366.
- HarrisGeospatial, 2019, Maximum Likelihood, Amerika Birleşik Devletleri, <https://www.harrisgeospatial.com/docs/MaximumLikelihood.html>: [14 Haziran 2019].
- Hayes, M. ve Decker, W. L., 1998, Using satellite and real-time weather data to predict maize production, *International Journal of Biometeorology*, 42 (1), 10-15.
- Ishida, T., Kurihara, J., Viray, F. A., Namuco, S. B., Paringit, E. C., Perez, G. J., Takahashi, Y. ve Marciano, J. J., 2018, A novel approach for vegetation classification using UAV-based hyperspectral imaging, *Computers and Electronics in Agriculture*, 144, 80-85.
- Jensen, J. R., 2007, Remote Sensing of the Environment: An Earth Resource Perspective, Academic Internet Pub Incorporated, p.
- Jia, K., Wu, B., Tian, Y., Zeng, Y. ve Li, Q., 2011, Vegetation classification method with biochemical composition estimated from remote sensing data, *International journal of remote sensing*, 32 (24), 9307-9325.
- Jiang, J., Zheng, H., Ji, X., Cheng, T., Tian, Y., Zhu, Y., Cao, W., Ehsani, R. ve Yao, X., 2019, Analysis and Evaluation of the Image Preprocessing Process of a Six-Band Multispectral Camera Mounted on an Unmanned Aerial Vehicle for Winter Wheat Monitoring, *Sensors*, 19 (3), 747.
- Jurado-Expósito, M., de Castro, A. I., Torres-Sánchez, J., Jiménez-Brenes, F. M. ve López-Granados, F., 2019, Papaver rhoeas L. mapping with cokriging using UAV imagery, *Precision Agriculture*.
- Karakış, S., 2012, İnsansız Hava Aracı Yardımıyla Büyük Ölçekli Fotogrametrik Harita Üretim Olanaklarının Araştırılması, *Harita Dergisi* (147), 13-20.
- Kule, A., 2015, İnsansız Hava Aracı Sistemleri Dünyü Bugünü Yarını, *İstanbul*, Beta Basım A.Ş., p.
- Lucieer, A., Robinson, S., Turner, D., Harwin, S. ve Kelcey, J., 2012, Using a micro-UAV for ultra-high resolution multi-sensor observations of Antarctic moss beds, p.
- Luhmann, T., Robson, S., Kyle, S. ve Harley, I., 2006, Close Range Photogrammetry: Principles, Methods and Applications, Whittles Publishing, p. 510.
- Ma, G., Zhao, Q., Wang, Q. ve Liu, M., 2018, On the Effects of InSAR Temporal Decorrelation and Its Implications for Land Cover Classification: The Case of the Ocean-Reclaimed Lands of the Shanghai Megacity, p.
- Martínez-Verduzco, G. C., Galeana-Pizaña, J. M. ve Cruz-Bello, G. M., 2012, Coupling Community Mapping and supervised classification to discriminate Shade coffee from Natural vegetation, *Applied Geography*, 34, 1-9.
- McHugh, S., 2019, DIGITAL CAMERA SENSORS, Cambridge, <https://www.cambridgeincolour.com/tutorials/camera-sensors.htm>: [11 Haziran 2019].
- NASA, 2011, Landsat Image Galery. Landsat 5 TM. istanbul_tm5_2011158. Amerika Birleşik Devletleri, NASA. 166 KB.
- Nex, F. ve Remondino, F., 2014, UAV for 3D mapping applications: A review, p.


- Örmeci, C., 1987, Uzaktan algılama:(temel esaslar ve algılama sistemleri), İstanbul Teknik Üniversitesi, p.
- Özkan, U. Y., 2006, Uydu görüntüleri yardımıyla meşcere parametrelerinin kestirilmesi ve orman amenajmanında kullanılması olanakları, *İstanbul Üniversitesi Orman Fakültesi Dergisi; 2006, Series A, Vol 56, No 2; 191-218.*
- Özyavuz, M., 2011, Bitki Örtüsünün Ekolojik Şartlarının Coğrafi Bilgi Sistemleri ve Uzaktan Algılama Teknikleri ile Analizi, Ganos (Işıklar) Dağı, Tekirdağ.
- Peña, J., Torres-Sánchez, J., Serrano-Pérez, A., de Castro, A. ve López-Granados, F., 2015, Quantifying Efficacy and Limits of Unmanned Aerial Vehicle (UAV) Technology for Weed Seedling Detection as Affected by Sensor Resolution, *Sensors*, 15 (3), 5609.
- Powell, R. ve Brooks, C., 2019, Land Use Land Cover Mapping in the Tiffin River Watershed, p.
- Primicerio, J., Di Gennaro, S. F., Fiorillo, E., Genesisio, L., Lugato, E., Matese, A. ve Vaccari, F. P., 2012, A flexible unmanned aerial vehicle for precision agriculture, *Precision Agriculture*, 13 (4), 517-523.
- Rashed, T. ve Jürgens, C., 2010, Remote sensing of urban and suburban areas, Springer Science & Business Media, p.
- Salamí, E., Barrado, C. ve Pastor, E., 2014, UAV Flight Experiments Applied to the Remote Sensing of Vegetated Areas, *Remote Sensing*, 6 (11), 11051.
- Schmidt, K. ve Skidmore, A., 2003, Spectral discrimination of vegetation types in a coastal wetland, *Remote Sensing of Environment*, 85 (1), 92-108.
- Sesören, A., 1998, Uzaktan Algılamada Temel Kavramlar, *İstanbul*, Mart Matbaacılık, p.
- Short, N. M. ve Robinson, J., 1999, Unsupervised Classification, Goddard Space Flight Center, NASA, http://priede.bf.lu.lv/GIS/.Descriptions/RST/Sect1/nicktutor_1-14.shtml: [14 Haziran 2019].
- Somers, B. ve Asner, G. P., 2014, Tree species mapping in tropical forests using multi-temporal imaging spectroscopy: Wavelength adaptive spectral mixture analysis, *International Journal of Applied Earth Observation and Geoinformation*, 31, 57-66.
- Sunar, F., Özkan, C. ve Osmanoglu, B., 2011, Uzaktan Algılama, *Eskişehir*, Anadolu Üniversitesi Yayınları, p.
- Toprak, A. S., 2014, Fotogrametrik tekniklerin insansız hava araçları ile mühendislik projelerinde kullanılabilirliğinin araştırılması, *Selçuk Üniversitesi Fen Bilimleri Enstitüsü*.
- USGS, 2019, Landsat 8, Amerika Birleşik Devletleri, https://www.usgs.gov/land-resources/nli/landsat/landsat-8?qt-science_support_page_related_con=0#qt-science_support_page_related_con: [09 Haziran 2019].
- Wikipedia, 2009, EM Spectrum Properties, https://tr.wikipedia.org/wiki/Dosya:EM_Spectrum_Properties_edit_tr.svg: [30.07.2019].
- Xie, Q.-y., Dash, J., Huang, W., Peng, D., Qin, Q., Mortimer, H., Casa, R., Pignatti, S., Laneve, G., Pascucci, S., Dong, Y. ve Ye, H., 2018, Vegetation Indices Combining the Red and Red-Edge Spectral Information for Leaf Area Index Retrieval, p.
- Yakar, M. ve Doğan, Y., 2017, Uzuncaburç Antik Kentinin İHA Kullanılarak Eğik Fotogrametri Yöntemiyle Üç Boyutlu Modellenmesi. 16. Türkiye Harita Bilimsel ve Teknik Kurultayı. Ankara, TMMOB Harita ve Kadastro Mühendisleri Odası.

- Yilmaz, M. ve Terzi, F., 2019, The Effects of Urban Spatial Development on Coastal Ecosystems: The Case of Mersin, Turkey, *IOP Conference Series: Materials Science and Engineering*, 471, 102026.
- Zhao, Y., Qunnie, P., Yi, C. ve Kong, S., 2016, Multiband Polarization Imaging, p.




EKLER


EK-1 Spektral Kalibrasyon yapmak üzere arazi ortamında çekilen farklı spektrumlardaki kalibrasyon kağıdı fotoğrafları; a) yeşil, b) kızılötesi c) kırmızı d) kızıl-kenar



EK-2 Çalışma alanına ait Yeşil (a) ve Kızılötesi (b) bantlarındaki görüntü




EK-3 Çalışma alanına ait Kırmızı (a) ve Kızıl-kenar (b) bantlarındaki görüntü




EK- 4 Çalışma alanına ait görünür bantlardaki görüntü





EK- 5 4 bandın birleştirilmesiyle oluşturulmuş olan kompozit false-colour görüntü

EK- 6 Ekinlere ait NDVI görüntüsü




EK- 7 ISODATA kümeleme yöntemi ile oluşturulmuş Kontrolsüz Sınıflandırma görüntüsü



EK- 8 Maximum Likelihood algoritması ile üretilmiş olan sınıflandırma görüntüsü

EK- 9 Support Vector Machine algoritması ile üretilmiş olan sınıflandırma görüntüsü



EK- 10 Support Vector Machine sınıflandırması ile arazi gerçekliğinin karşılaştırmasında kullanılan rastgele noktalara ait değerler (1=soya, 2=yonca, 3=toprak ve 4=yabani ot)

OBJECTID	Classified	GrndTruth						
			51	3	3	101	1	1
1	3	4	52	1	1	102	3	3
2	4	4	53	1	1	103	4	1
3	3	3	54	4	1	104	4	1
4	3	3	55	3	3	105	3	3
5	4	1	56	3	3	106	1	1
6	3	3	57	1	1	107	4	1
7	4	3	58	4	1	108	3	3
8	4	4	59	1	1	109	4	1
9	3	3	60	3	3	110	1	1
10	4	4	61	3	3	111	1	1
11	3	4	62	4	1	112	3	3
12	3	3	63	3	3	113	1	1
13	3	3	64	3	3	114	3	3
14	1	1	65	3	3	115	1	1
15	3	3	66	1	1	116	3	3
16	4	1	67	3	3	117	1	1
17	3	3	68	1	1	118	3	3
18	1	1	69	1	1	119	3	3
19	3	3	70	1	1	120	1	1
20	3	3	71	3	3	121	3	3
21	3	4	72	1	1	122	1	1
22	3	3	73	3	3	123	1	1
23	3	3	74	1	1	124	3	3
24	4	4	75	3	3	125	1	1
25	3	3	76	1	1	126	3	3
26	3	3	77	3	3	127	3	3
27	3	3	78	1	1	128	4	1
28	1	1	79	3	1	129	1	1
29	1	1	80	3	3	130	4	1
30	1	1	81	3	3	131	1	1
31	3	3	82	1	1	132	4	4
32	3	3	83	4	1	133	3	4
33	3	3	84	3	3	134	3	3
34	4	1	85	3	3	135	3	4
35	1	1	86	3	3	136	3	3
36	3	3	87	3	3	137	3	3
37	1	1	88	4	1	138	3	3
38	3	3	89	4	1	139	3	3
39	4	1	90	3	3	140	3	3
40	3	3	91	4	1	141	3	3
41	3	3	92	3	3	142	3	3
42	3	3	93	1	1	143	3	3
43	3	3	94	3	3	144	3	3
44	3	3	95	4	1	145	3	3
45	1	1	96	3	3	146	3	3
46	4	1	97	4	1	147	4	4
47	1	1	98	1	1	148	3	4
48	4	1	99	4	1	149	3	3
49	3	1	100	4	1	150	3	3
50	3	3						

151	3	4	201	1	1	251	1	1
152	3	4	202	3	3	252	3	3
153	3	3	203	1	1	253	3	3
154	3	3	204	1	4	254	3	3
155	3	3	205	3	3	255	3	4
156	3	3	206	1	1	256	4	4
157	3	3	207	1	1	257	3	3
158	3	3	208	1	1	258	3	4
159	4	4	209	2	1	259	3	3
160	3	4	210	3	3	260	1	4
161	3	3	211	1	1	261	4	4
162	3	3	212	3	3	262	4	4
163	3	3	213	3	4	263	4	4
164	4	4	214	1	1	264	1	4
165	3	3	215	3	3	265	4	4
166	3	3	216	3	3	266	4	4
167	1	1	217	4	4	267	1	1
168	3	3	218	3	3	268	1	4
169	3	3	219	2	2	269	4	4
170	3	3	220	3	3	270	1	1
171	3	3	221	3	3	271	3	4
172	3	3	222	3	3	272	1	1
173	4	2	223	3	3	273	1	1
174	3	3	224	2	2	274	1	1
175	3	3	225	3	3	275	1	1
176	4	2	226	3	3	276	1	1
177	2	2	227	4	4	277	1	1
178	3	3	228	4	4	278	4	4
179	3	3	229	4	4	279	1	1
180	3	3	230	3	3	280	1	1
181	2	2	231	4	4	281	1	1
182	2	2	232	4	4	282	1	1
183	2	2	233	2	2	283	1	1
184	2	2	234	2	2	284	1	1
185	3	3	235	3	3	285	1	1
186	3	3	236	4	4	286	1	1
187	3	3	237	4	4	287	1	1
188	2	2	238	4	4	288	1	1
189	4	2	239	4	4	289	1	1
190	3	3	240	2	2	290	1	1
191	2	2	241	3	4	291	1	1
192	3	3	242	3	4	292	1	1
193	3	3	243	3	4	293	1	1
194	3	4	244	4	4	294	1	4
195	1	1	245	3	4	295	1	1
196	1	1	246	1	1	296	3	3
197	4	2	247	1	4	297	4	4
198	4	4	248	4	4	298	1	1
199	1	1	249	4	4	299	1	4
200	1	1	250	1	1	300	1	4

EK- 10 Maximum Likelihood sınıflandırması ile arazi gerçekliğinin karşılaştırmasında kullanılan rastgele noktalara ait değerler (1=soya, 2=yonca, 3=toprak ve 4=yabani ot)

OBJECTID	Classified	GrndTruth						
1	3	4	51	3	3	101	1	1
2	1	4	52	1	1	102	3	3
3	3	3	53	1	1	103	4	1
4	3	3	54	4	1	104	4	1
5	1	1	55	3	3	105	3	3
6	3	3	56	3	3	106	1	1
7	3	3	57	1	1	107	4	1
8	1	4	58	4	1	108	3	3
9	3	3	59	1	1	109	4	1
10	4	4	60	3	3	110	1	1
11	1	4	61	3	3	111	1	1
12	3	3	62	1	1	112	3	3
13	3	3	63	3	3	113	1	1
14	1	1	64	4	3	114	4	3
15	3	3	65	3	3	115	1	1
16	4	1	66	1	1	116	3	3
17	3	3	67	3	3	117	1	1
18	1	1	68	1	1	118	3	3
19	3	3	69	1	1	119	3	3
20	3	3	70	1	1	120	1	1
21	3	4	71	3	3	121	3	3
22	3	3	72	1	1	122	1	1
23	3	3	73	3	3	123	1	1
24	4	4	74	1	1	124	3	3
25	3	3	75	3	3	125	1	1
26	3	3	76	1	1	126	3	3
27	3	3	77	3	3	127	3	3
28	1	1	78	1	1	128	4	1
29	1	1	79	4	1	129	1	1
30	1	1	80	3	3	130	4	1
31	3	3	81	4	3	131	1	1
32	3	3	82	1	1	132	4	4
33	3	3	83	4	1	133	4	4
34	4	1	84	3	3	134	3	3
35	1	1	85	3	3	135	3	4
36	3	3	86	3	3	136	3	3
37	1	1	87	3	3	137	3	3
38	3	3	88	4	1	138	3	3
39	1	1	89	4	1	139	3	3
40	3	3	90	3	3	140	3	3
41	3	3	91	1	1	141	3	3
42	3	3	92	3	3	142	3	3
43	3	3	93	1	1	143	3	3
44	3	3	94	3	3	144	3	3
45	1	1	95	1	1	145	3	3
46	4	1	96	3	3	146	3	3
47	1	1	97	4	1	147	4	4
48	1	1	98	1	1	148	4	4
49	3	1	99	4	1	149	3	3
50	3	3	100	4	1	150	3	3

151	1	4	201	1	1	251	1	1
152	4	4	202	3	3	252	3	3
153	3	3	203	1	1	253	3	3
154	3	3	204	4	4	254	3	3
155	3	3	205	3	3	255	3	4
156	3	3	206	1	1	256	4	4
157	3	3	207	1	1	257	3	3
158	3	3	208	1	1	258	4	4
159	4	4	209	1	1	259	3	3
160	4	4	210	3	3	260	1	4
161	3	3	211	1	1	261	4	4
162	3	3	212	3	3	262	4	4
163	3	3	213	4	4	263	4	4
164	4	4	214	1	1	264	1	4
165	3	3	215	3	3	265	4	4
166	3	3	216	3	3	266	4	4
167	1	1	217	4	4	267	1	1
168	3	3	218	3	3	268	1	4
169	3	3	219	2	2	269	4	4
170	3	3	220	3	3	270	1	1
171	3	3	221	3	3	271	4	4
172	3	3	222	3	3	272	1	1
173	2	2	223	3	3	273	1	1
174	3	3	224	2	2	274	1	1
175	3	3	225	3	3	275	1	1
176	1	2	226	3	3	276	1	1
177	2	2	227	4	4	277	1	1
178	3	3	228	4	4	278	4	4
179	3	3	229	4	4	279	1	1
180	3	3	230	3	3	280	1	1
181	2	2	231	4	4	281	1	1
182	2	2	232	4	4	282	1	1
183	2	2	233	2	2	283	1	1
184	2	2	234	2	2	284	1	1
185	3	3	235	3	3	285	1	1
186	3	3	236	1	4	286	1	1
187	3	3	237	4	4	287	1	1
188	2	2	238	4	4	288	1	1
189	2	2	239	4	4	289	1	1
190	3	3	240	2	2	290	1	1
191	2	2	241	4	4	291	1	1
192	3	3	242	4	4	292	1	1
193	3	3	243	4	4	293	1	1
194	4	4	244	4	4	294	1	4
195	1	1	245	4	4	295	1	1
196	1	1	246	1	1	296	3	3
197	1	2	247	1	4	297	4	4
198	4	4	248	4	4	298	1	1
199	1	1	249	4	4	299	4	4
200	1	1	250	1	1	300	1	4

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Yusuf Doğan
Uyruğu : Türkiye Cumhuriyeti
Doğum Yeri ve Tarihi : Mersin – 11/12/1989
Telefon : 0090 554 915 6535
Faks :
e-mail : yusufdogan89@gmail.com

EĞİTİM

Derece	Adı, İlçe, İl	Bitirme Yılı
Lise	: Silifke Anadolu Lisesi, Silifke, Mersin	2008
Üniversite	: Selçuk Üniversitesi, Selçuklu, Konya	2014
Yüksek Lisans	: Konya Teknik Üniversitesi, Selçuklu, Konya	-
Doktora	:	

İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
2014 - 2018	Silifke Belediyesi	Harita Mühendisi
2018 - Devam	Mersin Teknoloji Transfer Ofisi	Proje Destek Uzmanı

UZMANLIK ALANI

Harita Mühendisliği - Fotogrametri

YABANCI DİLLER

İngilizce

BELİRTMEK İSTEĞİNİZ DİĞER ÖZELLİKLER

YAYINLAR

Yıldız, F., ve Doğan, Y., 2019, İHA İle Multispektral Kameralardan Sağlanan Görüntüler Yardımıyla Bitki Türlerinin Sınıflandırılması, *TUFUAB 2019*, Aksaray-Türkiye, 464-470.