



T.C.
NECMETTİN ERBAKAN NİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

UZAKTAN ALGILAMA TEKNİKLERİ
KULLANILARAK KAYISI BAHÇELERİNİN
TESPİTİ VE REKOLTE TAHMİNİ;
MALATYA BATTALGAZİ ÖRNEĞİ

Ümmü Gülsüm ŞENTÜRK

YÜKSEK LİSANS TEZİ

Harita Mühendisliği Anabilim Dalı

Ekim-2020
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Ümmü Gülsüm ŞENTÜRK tarafından hazırlanan “Uzaktan Algılama Teknikleri Kullanılarak Kayısı Bahçelerinin Tespiti ve Rekolte Tahmini; Malatya Battalgazi Örneği ” adlı tez çalışması .../.../... tarihinde aşağıdaki jüri tarafından oy birliği / oy çokluğu ile Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü Harita Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Doç. Dr. Murat UYSAL

.....

Danışman

Dr. Öğr. Üyesi Abdullah VARLIK

.....

Üye

Doç. Dr. Hüseyin Zahit SELVİ

.....

Fen Bilimleri Enstitüsü Yönetim Kurulu’nun .../.../20.. gün ve sayılı kararıyla onaylanmıştır.

Prof. Dr. S. Savaş DURDURAN
FBE 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.

İmza

Ümmü Gülsüm ŞENTÜRK

Tarih:

ÖZET

YÜKSEK LİSANS TEZİ

UZAKTAN ALGILAMA TEKNİKLERİ KULLANILARAK KAYISI BAHÇELERİNİN TESPİTİ VE REKOLTE TAHMİNİ; MALATYA BATTALGAZİ ÖRNEĞİ

Ümmü Gülsüm ŞENTÜRK

Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü
Harita Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Abdullah VARLIK

2020, 65 Sayfa

Jüri

Doç. Dr. Murat UYSAL

Doç. Dr. Hüseyin Zahit SELVİ

Dr. Öğr. Üyesi Abdullah VARLIK

Dünyada yaşanan hızlı teknolojik gelişmeler diğer birçok alanda olduğu gibi uzaktan algılama tekniklerinden biri olan uydu görüntüleme de, önemli gelişmeleri beraberinde getirmiştir. Avrupa Uzay Ajansı(ESA) tarafından oluşturulan Avrupa Copernicus programının bir parçası olan Sentinel-2 verileri yüksek tekrar ziyaret süresi, geniş kapsama alanı ve yüksek mekânsal ve spektral çözünürlüklü görüntü sağlaması dolayısıyla birçok uygulamada olduğu gibi tarım uygulamalarında da yaygın olarak kullanılmaktadır.

Ürün türlerinin belirlenmesi, verim tahmini için ilk adım niteliğindedir. Hasattan önce üretilen mahsul tipi haritalar, ülke ekonomisi adına yapılacak planlamalar için büyük önem arz etmektedir. Yapılan çalışmada Sentinel-2 uydu verilerinin sınıflandırılmasıyla Malatya ili Battalgazi ve Yeşilyurt ilçelerinde kayısı bahçelerinin tespiti yapılmıştır. Sınıflandırma işlemi sonucunda genel doğruluk %96.5 olarak hesaplanmıştır. Kayısı bahçeleri tespiti yapıldıktan sonra 400 m aralıklarla nokta atılmış ve bu noktaların NDVI (Normalize Edilmiş Fark Bitki Örtüsü İndeksi) değerleri okutulmuştur. Elde edilen bu değerler rekolte tahmini amacıyla Malatya Ticaret ve Sanayi Odası rekolte tahmini verileriyle birlikte kullanılarak Malatya ili Battalgazi ve Yeşilyurt ilçeleri için bazı istatistiksel hesaplamalar yapılmıştır. Yapılan hesaplamaların ardından Battalgazi ve Yeşilyurt ilçelerinin 2018 ve 2019 yılı rekolte tahmini oranları ile Mayıs ayı NDVI oranları arasında bir korelasyon olduğu saptanmıştır. Elde edilen sonuçlar rekolte tahmini için Mayıs ayı NDVI verilerinin kullanılabilceğini göstermiştir.

Anahtar Kelimeler: Kayısı, NDVI, Rekolte Tahmini, Sentinel-2

ABSTRACT

MS THESIS

DETERMINATION AND YIELD ESTIMATION OF APRICOT GARDENS BY USING REMOTE SENSİNG TECHNIQUES; MALATYA BATTALGAZI SAMPLE

Ümmü Gülsüm ŞENTÜRK

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF
NECMETTİN ERBAKAN UNIVERSITY
THE DEGREE OF MASTER OF SCIENCE
IN GEOMATICS ENGINEERING**

Advisor: Assist. Prof. Abdullah VARLIK

2020, 65 Pages

Jury

Assoc. Prof. Murat UYSAL

Assoc. Prof. Huseyin Zahit SELVI

Assist. Prof. Abdullah VARLIK

The rapid technological developments in the world have brought about important developments in satellite imaging, which is one of the remote sensing techniques as in many other fields. Sentinel-2 data, which is a part of the European Copernicus program created by the European Space Agency (ESA), is widely used in agricultural applications as well as in many applications due to its high revisit time, wide coverage and high spatial and spectral resolution images.

Determination of crop types is the first step for yield estimation. Crop-type maps produced before harvest are of great importance for planning on behalf of the country's economy. In this study, by using the Sentinel-2 satellite data classification, apricot orchards were determined in Battalgazi and Yeşilyurt districts of Malatya province. As a result of the classification process, the overall accuracy was calculated as 96.5%. After the determination of apricot branches, the points were taken at 400 m intervals and NDVI (Normalized Difference Vegetation Index) values of these points were read. Some statistical calculations were made for Battalgazi and Yeşilyurt districts of Malatya province by using these values together with the yield estimation data of Malatya Chamber of Commerce and Industry for yield estimation. After the calculations, it was found that there is a correlation between yield estimates of 2018 and 2019 and May NDVI rates of Battalgazi and Yeşilyurt districts. The results showed that May NDVI data could be used for yield estimation.

Keywords: Apricot, NDVI, Sentinel-2, Yield Estimation

ÖNSÖZ

“Uzaktan Algılama Teknikleri Kullanılarak Kayısı Bahçelerinin Tespiti ve Rekolte Tahmini; Malatya Battalgazi Örneği” isimli bu çalışma Necmettin Erbakan Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Harita Mühendisliği Yüksek Lisans Tezi olarak hazırlanmıştır.

Çalışmam sırasında görüşlerinden ve bilgisinden istifade ettiğim danışmanım değerli hocam Sayın Dr. Öğr. Üyesi Abdullah VARLIK’a
Bölümümüzde görev yapmakta olan değerli öğretim elemanlarına,
Hayatımın her alanında desteklerini benden esirgemeyen değerli aileme;
Teşekkürlerimi sunarım.

Ümmü Gülsüm ŞENTÜRK
KONYA-2020

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
SİMGELER VE KISALTMALAR	ix
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMASI	3
3. UZAKTAN ALGILAMA	6
3.1 Uzaktan Algılamanın Temel Bileşenleri.....	6
3.2. Elektromanyetik Radyasyon ve Elektromanyetik Spektrum	7
3.3. Enerji- Atmosfer Etkileşimi	10
3.4. Enerji- Nesne Etkileşimi ve Nesnelerin Spektral İmzası.....	11
3.5. Uzaktan Algılamada Görüntü Kaynaştırma (Füzyonu).....	14
3.6. Uzaktan Algılamada Görüntü Sınıflandırma	16
3.6.1. Kontrollü Sınıflandırma	16
3.6.2. Kontrolsüz Sınıflandırma.....	17
3.7. Sınıflandırma Doğruluğu	18
3.8. Uzaktan Algılamada Oran Görüntüleri.....	20
3.8.1. Normalleştirilmiş Fark Bitki Örtüsü İndeksi (NDVI).....	20
4. REKOLTE TAHMİNİ	23
4.1 Rekolte Tahmini Uygulama Alanları ve Önemi	23
4.2. Rekolte Tahmininde Uzaktan Algılamanın Rolü.....	24
5. UYGULAMA	26
5.1. Çalışma Alanı ve Veriler	26
5.1.1. Çalışma Alanı	26
5.1.2. Veriler	27
5.2. Yöntem.....	31
5.2.1. Görüntülerin İyileştirilmesi.....	31
5.2.2. Görüntülerin Sınıflandırılması.....	32
5.2.3. Sınıflandırılmış Görüntünün Filtrelenmesi	32
5.2.4. Doğruluk Analizi	33
5.2.4. NDVI Görüntülerinin Oluşturulması	34
5.2.5. Görüntülere Belli Aralıklarla Nokta Atılması	42
5.2.6. Noktaların NDVI Değerlerinin Okutulması	44

6. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....	45
6.1. NDVI Değerleri İstatistiksel Hesaplamalar	45
6.2. NDVI - Rekolte İlişkisi.....	45
6.3. NDVI Oranları - Rekolte Oranları İlişkisi	47
7. SONUÇLAR VE ÖNERİLER	49
8. KAYNAKLAR	51

SİMGELER VE KISALTMALAR

Kısaltmalar

DN: Dijital Numara
EM: Elektromanyetik
EMR: Elektromanyetik Spektrum
IHS: Yoğunluk-ton-doygunluk
MS: Çokbantlı
N: Azot
NDVI: Normalleştirilmiş Fark Bitki Örtüsü İndeksi
NIR: Yakın Kızılötesi
PAN: Tek bantlı
SWIR: Kısa dalga kızılötesi
VI: Vejetasyon indeksi
VIS-NIR: Görünür bölge - Kızılötesi
µm: Mikron

1. GİRİŞ

Artan hızlı nüfus artışı nedeniyle gıda güvenliğini sağlama sorunu günümüzde yaşanan ana kaygılardan biridir. Mevcut ve öngörülen gıda kıtlığından kaynaklanan ekonomik ve sosyal sorunları çözmek amacıyla, 2050 yılına kadar gıda talebini karşılamak için bir milyar hektar yeni ekim alanı gerekli olacaktır (Gong ve ark., 2012; Siachalou ve ark., 2015). Bu nüfus artışı, dünya genelinde gıda tedarik sistemlerini etkileyerek (Waldner ve ark., 2015; Belgiu ve Csillik, 2018), sürdürülebilir doğal kaynak yönetimi programlarının geliştirilmesini de acil hale getirmektedir (Belgiu ve Csillik, 2018).

Dünyada yaşanan hızlı teknolojik gelişmeler diğer birçok alanda olduğu gibi uzaktan algılama tekniklerinden biri olan uydu görüntüleme de, önemli gelişmeleri beraberinde getirmiştir. Özellikle son on yılda, uydu görüntüleri, Dünya yüzeyinin ince ve uzamsal ölçeklerde izlenmesi ile ilgili değerli bir bilgi kaynağı sunmaktadır. Uydu tabanlı dünya gözlemi mahsul tiplerini çeşitli çevresel koşullar altında haritalamak, çeşitli spektral bölgelerdeki tarlaların sinoptik kapsamını sağlamak, mevcut coğrafi veritabanları ile geleneksel istatistikî araştırmalara göre düşük maliyetli ve zaman kazandıran bir yaklaşımla sorunsuz entegrasyon sağlamak için kullanılmıştır (Ozdoğan ve ark., 2010 ; Siachalou ve ark., 2015).

Yüksek maliyet ve tarımsal üretimin geniş kapsama alanı, güçlü mevsimsel ve mekânsal heterojenite gibi özelliklerinden dolayı geleneksel arazi ölçüm yöntemlerinden yıllık ürün bilgisi elde etmek oldukça zordur (Nagraj ve Karegovda, 2016). Uydu gözlemleri, mahsul türü, mahsul koşulları ve tarla seviyesinden mahsul verimi, ülkeler veya kıtalar gibi genişletilmiş coğrafi alanlara kadar mahsul verimi hakkında bilgi sağlamada rol oynayabilir (Rembold ve ark., 2013). Bu bağlamda Avrupa Uzay Ajansı tarafından Copernicus Projesi kapsamında oluşturulan Sentinel serisi uyduların piyasaya sürülmesi, ekim alanı haritalamasında ve verimli tarım izlemede doğruluğu artırmak için mükemmel fırsatlar sunmaktadır. Sentinel-2 ikiz uyduları, kısa tekrar ziyaret süresi (5 gün), yüksek uzamsal çözünürlük (10 metre) ve kırmızı kenarlı spektrumunda bir dizi bant avantajına sahiptir (Duraismy, 2019).

Ürün türlerinin belirlenmesi, verim tahmininin ilk adımıdır (Nagraj ve Karegovda, 2016). Sezonun sonundan önce üretilen mahsul tipi haritalar, politika ve karar vericiler tarafından yönetim, istatistik ve ekonomik amaçlarla kullanılmak adına talep edilmektedir (Immitzer ve ark., 2016).

Ülkemiz elverişli büyük tarım alanlarına sahip olması dolayısıyla ekonomik getirisi yüksek olan tarım ürünlerinin hasat öncesi verim tahminleri, iç piyasa fiyatlarının belirlenmesi ve ülke ekonomisi adına yapılacak planlamalar için büyük önem arz etmektedir (Esetlili ve ark., 2015).

Türkiye, ekonomik getirisi yüksek değere sahip önemli ihracat ürünlerinden biri olan kayısının dünya çapında en büyük üreticisi konumundadır. Ülkemizde yaklaşık 1.2 milyon dekarlık alanda kayısı yetiştiriciliği yapılmaktadır. Başta Malatya olmak üzere ülkemizde Elazığ, Sivas, Kahramanmaraş ve Mersin'de yapılan yaş kayısı üretimi yapılmaktadır (URL-1).

Bu çalışmada Sentinel-2B uydu verileri kullanılarak kontrollü sınıflandırma yöntemi ile Malatya ili Battalgazi ve Yeşilyurt ilçelerinde kayısı ekili alan tespiti yapılarak Battalgazi ve Yeşilyurt ilçeleri için NDVI analizleri ve Malatya Ticaret ve Sanayi Odası Battalgazi ve Yeşilyurt ilçelerinin rekolte tahmin verilerinin NDVI verileriyle ilişkisi irdelenerek rekolte tahmini amacıyla kullanılabilirliğinin irdelenmesi amaçlanmıştır.

Çalışmanın giriş bölümünde uzaktan algılamanın ürün tespitinde kullanımı ve rekolte tahmini ile birlikte çalışma konusu hakkında genel bilgiler verilmiştir. İkinci bölümde ise kaynak araştırmasına yer verilmiştir. Üçüncü bölümde uzaktan algılamanın temel kavramlarından olan elektromanyetik enerji, elektromanyetik spektrum, enerji atmosfer etkileşimi ve enerji yeryüzü cisimleriyle etkileşimi ve bu cisimlerin spektral özellikleri hakkında bilgi verilmiş olup uzaktan algılamada görüntü kaynaştırma ve görüntü sınıflandırma ve ardından sınıflandırma doğruluna değinilmiş olup oran görüntüleri açıklanmıştır. Dördüncü bölümde rekolte tahmini önemi, uygulama alanları ve uzaktan algılama ile ilişkisine yer verilmiştir. Beşinci bölümde çalışma alanı, verilerin elde edilmesi, işlenmesi detaylı olarak incelenmiştir. Altıncı bölümde NDVI rekolte ilişkisi irdelenmiş olup sonuç ve öneriler bölümünde Sentinel-2 verilerinin bu tarz uygulamalarda kullanılabilirliği denetlenmiştir.

2. KAYNAK ARAŞTIRMASI

Mahsul stresini etkileyen faktörlerin belirlenmesinde, mahsul verim değişikliklerinin simülasyonunda ve öngörülmesinde ve piyasa risklerinin analiz edilmesinde bölgeye özgü mahsul envanterleri, oldukça önemlidir (Doraiswamy ve ark., 2003; Monfreda ve ark., 2008; Mittal, 2012; Duraisamy, 2019). Mahsul alanı kapsamı tahminleri ve mahsul tipi haritaları tarımsal izleme ve yönetim için de önemli bilgiler sağlamaktadır (Inglada ve ark., 2016).

Mahsul türlerini belirlemek için uydu uzaktan algılama verilerinin kullanılması yaygındır, çünkü bu veriler çeşitli zamansal ve mekansal ölçeklerdeki geniş alanları kapsamaktadır (Heupel ve ark., 2018). Uydu tabanlı mahsul haritalarının doğruluğunda, görüntülerin uzamsal çözünürlüğü, sınıflandırma yöntemi ve üretim zaman dilimi, yani veri setinin zamansal kapsamı ve kapsanan fenolojik aşamalar gibi bir dizi faktör etkilidir (HubertMoy ve ark., 2001 ; Van Niel ve McVicar, 2004; Duveiller ve Defourny, 2010, Azar ve ark., 2016). Ürün türü sınıflandırması ile ilgili önceden yapılmış çalışmalar, uygulanan yöntem, veri setlerinin sayısı ve türü, çalışma alanı ve ayrıştırılacak ürün türleri ve ayrıca tarla ve eğitim verilerinin mevcudiyeti ile ilgili olarak farklılık göstermektedir. Sonuç olarak, birden fazla bölgesel koşul ve özellik nedeniyle tutarlı bir ürün tipi sınıflandırma yaklaşımı yoktur (Heupel ve ark., 2018). Literatürde çeşitli sınıflandırma yöntemleri kullanılarak uydu görüntüleri ile ürün tespiti yapılan birçok uygulama mevcuttur.

Uça Avcı ve Sunar (2010) Türkgeldi Tarım İşletmesi Müdürlüğü'ne ait bir alanda yaptıkları çalışmada SPOT-4 uydu görüntülerini kullanarak mahsul türü tespiti için nesne tabanlı sınıflandırma yapmışlardır. Çalışmada bazı sınıflar birden çok özellikle tanımlandığı için bulanık(fuzzy) ve kesim dağılım(crisp) fonksiyonlarının ikisi de kullanılmıştır. Sınıflandırma genel doğruluğu % 80 olarak bulunmuştur.

Nitze ve ark. (2012) tarafından yapılan çalışmada Destek Vektör Makineleri (SVM), Yapay Sinir Ağları (ANN) ve Rastgele Orman algoritmalarının her biri geleneksel sınıflandırma yöntemi olan Maksimum Olabilirlik algoritmasıyla karşılaştırılmıştır. Kanada bozkırlarından 2009 yaz sezonuna ait 512 tarım alanında bulunan 10 adet farklı ürün RapidEye uydu görüntüleriyle sınıflandırılmıştır. Radyal temel işlev veya polinom çekirdekleri kullanan Destek Vektör Makineleri sınıflandırıcıları, genel doğruluk bakımından Yapay Sinir Ağları ve Rastgele Orman

algoritmasına göre daha yüksek doğruluk sağladığı ve Maksimum Olabilirlik algoritmasının daha düşük kaliteli doğruluk sağladığı belirtilmiştir.

Akar ve Güngör (2013) Worldview-2 uydu görüntülerini kullanarak çay ve fındık ekili alanları belirlemek için yaptıkları çalışmada Eş Dizimlilik (co-occurrence) Matrisi ve Rastgele Orman sınıflandırma algoritmasını kullanmışlardır. Rastgele Orman algoritması ile elde edilen sınıflandırma doğruluğu % 79,05 olarak bulunurken Eş Dizimlilik Matrisi ile elde edilen doğruluk %84,08 olmuştur. Çalışma sonucu Eş Dizimlilik Matrisi ile elde edilen doku özelliklerinin sınıflandırma doğruluğunu arttırdığını göstermiştir.

Ustuner ve ark. (2014) yaptıkları çalışmada RapidEye uydu görüntülerinden elde ettikleri üç farklı bitki örtüsü indeksi olan NDVI(Normalize Edilmiş Fark Bitki Örtüsü İndeksi), GNDVI(Yeşil Band Normalize Edilmiş Fark Bitki Örtüsü İndeksi) ve NDRE(Normalize Edilmiş Fark Kırmızı Kenar İndeksi) indekslerini kullanarak mahsul tipi sınıflandırma analizi yaparak her bir indeksin sınıflandırma doğruluğuna etkisini incelemişlerdir. Çalışma sonucunda en yüksek sınıflandırma doğruluğu % 87,46 olarak bulunmuş olup sınıflandırma doğruluğu en yüksek olan bitki örtüsü indeksinin NDRE(Normalize Edilmiş Kırmızı Kenar İndeksi) olduğu sonucuna varılmıştır.

Uça Avcı ve Sunar (2014) tarafından Meriç havzasında yapılan çalışmada çok zamanlı Radarsat-1 uydu görüntülerini kullanarak nesne tabanlı sınıflandırma yöntemi ile pirinç ekili alanların tespiti yapılmıştır. Sınıflandırma doğruluğu % 92'dir. Yapılan çalışma ayrıca aynı veri seti kullanılarak daha önce Maksimum Benzerlik yöntemiyle yapılan piksel tabanlı sınıflandırma sonuçları ile karşılaştırılarak nesne tabanlı sınıflandırmanın daha yüksek doğruluk sağladığı ifade edilmiştir.

Lussem ve ark. (2016) Orta Avrupa'da kış mahsulleri(kışlık buğday/çavdar,kışlık arpa ve koza tohumu) için bir ürün tipi haritası oluşturmak amacıyla Sentinel-1 SAR ve RapidEye uydu verileri birleştirilerek Destek Vektör Makineleri ve Maksimum Olabilirlik algoritmaları karşılaştırılmıştır. Destek Vektör Makinelerinin diğer algoritmalara göre daha yüksek doğruluk sağladığı saptanmıştır. Çalışma sonucunda optik veri temininin sınırlı olduğu durumlarda optik ve radar verilerin kombinasyonunun umut vadeci olduğu vurgulanmıştır.

Delen ve Balık Şanlı (2017) tarafından RapidEye uydu görüntüleri kullanılarak yapılan çalışmada nesne tabanlı sınıflandırma yöntemi ile pamuk ekili alanlar bulunmuştur. Sınıflandırma genel doğruluğu %98,19 olarak hesaplanmıştır.

Saini ve Ghosh (2018) Hindistan'da yaptıkları çalışmada tek tarihli Sentinel-2 görüntülerini kullanarak Destek Vektör Makineleri ve Rastgele Orman algoritmalarını kullanarak ürün tespiti amacıyla sınıflandırma yapmışlardır. Çalışma alanında yüksek yoğunluklu orman, düşük yoğunluklu orman, kumlu alan, su, nadas arazisi, yerleşim, meyve bahçesi, buğday, şeker kamışı, yem ve diğer mahsuller olmak üzere on bir sınıf oluşturulmuş olup seçilen bölgedeki en önemli ürün şeker kamışı ve buğdaydır. Çalışmada Rastgele Orman algoritmasının Destek Vektör Makineleri algoritmasına göre daha iyi performans gösterdiği sonucuna varılmıştır.

Literatürde uzaktan algılama teknikleri kullanılarak rekolte tahmini amacıyla yapılmış çalışmalar mevcuttur.


Van Beek ve ark. (2015) tarafından Belçika'da yapılan bir çalışmada sulu ve yağmurla beslenen armut bahçelerinde, Normalleştirilmiş Fark Su İndeksi (NDWI), Fotokimyasal Yansıtma Endeksi (PRI) ve Kırmızı Kenar Normalleştirilmiş Fark Bitki Örtüsü Endeksi (ReNDVI) gibi spektral bitki örtüsü indeksleri yoluyla meyve veriminin zamansal bağımlılığı ve kalite tahminleri araştırılmıştır. Her iki meyve bahçesi de spektral ölçümler (yani hiperspektral gölgelik yansıtma ölçümleri) ve verim belirleme (yani ağaç başına toplam verim ve meyve sayısı) ve kalite değerlendirmesi (yani meyve sıklığı, toplam çözünür katı madde ve meyve rengi) dahil olmak üzere art arda üç büyüyen mevsim boyunca izlenmiştir. Çalışma sonuçları, spektral bitki örtüsü indeksleri ile hem meyve verimi hem de meyve kalitesi arasında açık bir ilişki olduğunu göstermiştir. Çalışmada, bitkisel büyüme dönemlerinde (yağmurla beslenen meyve bahçeleri) ve sonrasında (sulanan meyve bahçeleri) uzaktan algılama misyonunun daha iyi planlanması, üreticilerin üretim sonuçlarını daha doğru tahmin etmelerini ve üretim sürecini iyileştirmelerini sağlayabileceği vurgulanmıştır.

Robson ve ark. (2016) WorldView-3 uydu verilerini kullanarak macadamia fındığı ve avokado bitkileri için verim tahmini amacıyla yaptıkları çalışmada bitki örtüsü indeksleri ve verim arasındaki ilişki irdelenmiştir. Sonuçlar, elde edilen bitki örtüsü indeksleri ile meyve ağırlığı (kg / ağaç) arasında pozitif bir ilişki olduğunu (Macadamia için $R^2 > 0.69$ ve Avokado için $R^2 > 0.68$) göstermiştir.

3. UZAKTAN ALGILAMA

Uzaktan algılama, dünya yüzeyini fiziksel bir temas olmaksızın gözlemlemek ve dünya üzerindeki belirli nesnelere hakkında anlamlı bilgi edinmek için (Buiten ve ark., 1993; Kerle ve ark., 2004) elektromanyetik enerji ve madde arasındaki etkileşimi kaydeden görüntüleri elde etme, işleme ve yorumlama bilimidir (Sabins, 1996; Kerle ve ark., 2004).

Uzaktan algılama sistemleri, bilgiyi kaydetmek için kullanılan enerji kaynağına dayanarak aktif ve pasif olmak üzere iki gruba ayrılır. Pasif uzaktan algılama sistemleri, doğal olarak bulunan ve pasif sensörler olarak adlandırılan enerjiyi ölçer. Güneş enerjisi, VIS-NIR dalga boyları için olduğu gibi yansıtılır veya termal IR dalga boyları için olduğu gibi emilir ve sonra yeniden verilir. Pasif sensörler, yansıtılan veya yeniden gönderilen tüm güneş enerjisi mevcut olduğunda enerjiyi algılayabilir (Şekil 3.1.). Aktif algılama sistemleri ise güneş enerjisine ihtiyaç duymazlar. Aktif sensörlerin, araştırılacak özelliklerin belirlenmesi için kendi enerji kaynakları vardır. Hedef özelliğinden yansıtılan enerji, günün saatine veya mevsime bakılmaksızın aktif sensör tarafından kaydedilir (Şekil 3.2.) (Gupta, 2018).



Şekil 3.1. Pasif algılama



Şekil 3.2. Aktif algılama

3.1 Uzaktan Algılamanın Temel Bileşenleri

1. Enerji Kaynağı (A) : Uzaktan algılamanın ilk gereksinimi, hedefi aydınlatan veya elektromanyetik enerji sağlayan bir enerji kaynağına sahip olmaktır.

2. Radyasyon ve Atmosfer (B): Enerji, kaynağından hedefe giderken içinden geçtiği atmosfer ile etkileşime girer.


3. Hedefle Etkileşim (C): Enerji atmosfer yoluyla hedefe ulaştığında, hem hedefin hem de radyasyonun özelliklerine bağlı olarak hedefle etkileşime girer.

4. Enerjinin Algılayıcı Tarafından Kaydedilmesi (D): Enerji hedefe dağıldıktan veya hedeften yayıldıktan sonra, elektromanyetik radyasyonu toplamak ve kaydetmek için bir algılayıcıya ihtiyaç vardır.

5. Aktarma, Alım ve İşleme (E): Algılayıcı tarafından kaydedilen enerjinin, genellikle elektronik biçimde, verilerin bir görüntüye (basılı kopya ve / veya dijital) işlendiği bir alıcı ve işleme istasyonuna iletilmesi gerekir.

6. Yorum ve Analiz (F): İşlenen görüntü, aydınlatılan hedef hakkında bilgi elde etmek için görsel ve / veya dijital veya elektronik olarak yorumlanır.

7. Uygulama (G): Hedefle ilgili görüntülerden çıkardığımız bilgilerin bazı yeni bilgileri ortaya çıkarmak veya belirli bir problemi çözmeye yardımcı olacak biçime getirilmesi amacıyla yapılan işlemlerdir (Şekil 3.3.) (URL-2).




Şekil 3.3. Uzaktan Algılamanın Temel Bileşenleri

3.2. Elektromanyetik Radyasyon ve Elektromanyetik Spektrum

Uzaktan algılama için ilk gereklilik, hedefi aydınlatmak için bir enerji kaynağına sahip olmaktır. Bu enerji elektromanyetik radyasyon şeklindedir. Tüm elektromanyetik radyasyon dalga teorisinin temellerine göre öngörülebilir şekilde davranır. Elektromanyetik radyasyon, radyasyonun hareket ettiği yöne dik bir yönde büyüklük

olarak deęişen bir elektrik alanı (E) ve elektrik alanına dik açılarla yönlendirilmiş bir manyetik alandan (M) oluşur. Bu iki alan da ışık hızında (c) ilerler (Şekil 3.4.) (URL-2).



Şekil 3.4. Elektromanyetik Dalga Yayılımı

Uzaktan algılama verilerinden çıkarılacak bilgilerin anlaşılması için elektromanyetik radyasyonun iki özellięi oldukça önemlidir. Bunlar dalga boyu ve frekanstır. Dalga boyu, ardışık dalga tepeleri arasındaki mesafe olarak ölçülebilen bir dalga döngüsünün uzunluęudur. Frekans, birim zaman başına sabit bir noktadan geçen bir dalganın döngü sayısını ifade eder. Dalga boyu ve frekans aşağıdaki formülle ilişkilidir:

$$C = \lambda \cdot v$$

λ = dalga boyu(m)

v = frekans(saniyedeki döngü,Hz)

c = ışık hızı(3×10^8 m/sn) (URL-2).

Birçok farklı elektromanyetik dalga türü vardır. Artan frekans sırasına göre yerleştiren tüm elektromanyetik dalga aralığına elektromanyetik spektrum denir. Elektromanyetik spektrum; gamma ışınları, X ışınları, mor ötesi (ultraviyole) ışınlar, görünür ışınlar, kızılötesi ışınlar, mikrodalga ve radyo dalgalarını içeren bir aralıktan oluşur (URL-3) (Şekil 3.5.). Uzaktan algılama elektromanyetik spektrumun çeşitli bölgelerinde çalışır.

Gamma ışınları, elektromanyetik spektrumdaki diğer dalgaların en küçük dalga boylarına ve en fazla enerjisine sahiptir. Bu dalgalar radyoaktif atomlar tarafından ve nükleer patlamalarda üretilir. Gama ışınları, canlı hücreleri öldürebilme özelliğine sahiptir. Bu nedenle tıp alanında, kanserli hücreleri öldürmek amacıyla kullanılmaktadır (URL-4).

X ışınları, gamma ışınlarından daha yüksek dalga boyuna sahip elektromanyetik dalgalarıdır. Sahip oldukları yüksek enerjiden dolayı çoğu maddeye nüfuz edebilirler (URL-3). Vücuttaki kemik yapılarını görüntülemek için görüntüleme teknolojisinde yaygın olarak kullanılırlar (URL-5).


Mor ötesi (Ultraviyole) ışınlar, elektromanyetik spektrumdaki, uzaktan algılama için pratik olan en kısa dalga boylarına sahiptir. Kayalar ve mineraller gibi bazı yeryüzü maddeleri, ultraviyole radyasyonu ile aydınlatıldığında görünür ışık yayarlar (URL-2).

Görünür ışınlar, elektromanyetik spektrumun insan gözüyle görülebilen bölümüdür ve dalga boyları yaklaşık 0,4 ila 0,7 μm aralığındadır. Spektrumun bu kısmı, hepsi belirli bir dalga boyunu temsil eden bir dizi farklı renk içerir. Her görünür rengin dalga boyu vardır. Kırmızıdan mora doğru ilerledikçe, dalga boyu azalır ve enerji artar (URL-6).

Kızılötesi ışınlar, elektromanyetik spektrumun dalga boyu yaklaşık 0,7 μm ila 100 μm aralığında olan bölgesidir. Kızılötesi bölge, radyasyon özelliklerine göre yakın kızılötesi ve termal kızılötesi olmak üzere iki grupta incelenmektedir. Yansıyan kızılötesi bölgesindeki radyasyon, görünür kısımdaki radyasyona çok benzer şekillerde uzaktan algılama amacıyla kullanılır. Yakın kızılötesi yaklaşık 0,7 μm ila 3,0 μm arasındaki dalga boylarını kapsar. Termal kızılötesi bölge, görünür ve yakın kızılötesi kısımlarından farklıdır, çünkü bu enerji esas olarak Dünya yüzeyinden ısı şeklinde yayılan radyasyondur. Termal kızılötesi yaklaşık 3,0 μm ila 100 μm arasındaki dalga boylarını kapsar (URL-2).

Mikrodalga, 1 mm ila 1 m arasında değişen dalga boylarına sahiptir. Bu bölge, uzaktan algılama için kullanılan en uzun dalga boylarını kapsar (URL-2). Orta dalga boylu mikrodalgalar pusun içine girebilir, hafif yağmur ve kar, bulutlar ve duman uydu iletişimi ve Dünya'yı uzaydan incelemek için faydalıdır (URL-7).

Radyo dalgaları, elektromanyetik spektrumdaki en uzun dalga boylarına sahiptir. Radyo dalgaları çeşitli verileri iletmek için kullanılır. Kablosuz ağ, televizyon ve amatör radyoların tümü radyo dalgalarını kullanır (URL-7).



Şekil 3.5. Elektromanyetik Spektrum (tr.wikipedia.org)

3.3. Enerji- Atmosfer Etkileşimi

Uzaktan algılama için kullanılan radyasyon Dünya yüzeyine ulaşmadan önce Dünya atmosferinin belirli bir mesafesinden geçmelidir. Atmosferdeki parçacıklar ve gazlar gelen ışığı ve radyasyonu etkileyebilir. Bu etkiler saçılma ve yutulma mekanizmalarından kaynaklanır (URL-2).

Atmosferde saçılma, atmosferde bulunan parçacıklar veya gaz halindeki moleküller elektromanyetik dalgaların orijinal yollarından yönlendirilmesine neden olduğunda ortaya çıkar. Saçılma miktarı, radyasyonun dalga boyu, parçacık ve gaz miktarı ve radyasyonun atmosferde kat ettiği mesafe gibi çeşitli faktörlere bağlıdır. Rayleigh saçılması, Mie Saçılması ve Seçici olmayan saçılma olmak üzere üç tip saçılma vardır (Gupta, 2018). Rayleigh saçılımı, radyasyon, etkileşen radyasyonun dalga boyundan çok daha küçük çaplı atmosferik moleküller ve diğer küçük parçacıklarla etkileşime girdiğinde yaygındır. Rayleigh saçılımının etkisi, dalga boyunun dördüncü gücü ile ters orantılıdır. Bu nedenle, kısa dalga boylarının saçılma eğilimi çok daha güçlüdür."Mavi" bir gökyüzü Rayleigh saçılımının bir tezahürüdür. Güneş ışığı dünyanın atmosferiyle etkileşime girdiğinde, daha kısa (mavi) dalga boylarını diğer görünür dalga boylarından daha baskın olarak dağıtır. Sonuç olarak mavi bir gökyüzü görürüz. Rayleigh saçılması, görüntülerdeki "pus" un da ana nedenlerinden biridir.

Başka bir saçılma türü, atmosferik parçacık çapları algılanan enerji dalga boylarına esasen eşit olduğunda var olan Mie saçılımıdır. Su buharı ve toz, Mie saçılımının başlıca nedenleridir. Bu saçılma türü, Rayleigh saçılımına kıyasla daha uzun dalga boylarını etkileme eğilimindedir. Rayleigh saçılması çoğu atmosferik koşulda baskın olma eğiliminde olmasına rağmen, Mie saçılması hafif bulutlu olanlarda önemlidir.

Diğer bir saçılma türü de saçılmaya neden olan parçacıkların çapları algılanan enerji dalga boylarından çok daha büyük olduğunda ortaya çıkan seçici olmayan saçılımıdır. Örneğin, su damlacıkları, bu tür saçılmalara neden olurlar. Görünür ve yansıyan tüm IR dalga boylarını eşit olarak dağıtırlar. Görünür dalga boylarında, eşit miktarlarda mavi, yeşil ve kırmızı ışık saçılır, bu da sis ve bulutların beyaz görünmesini sağlar (URL-8).

Atmosferde bulunan gaz molekülleri, belirli spektral bantlarda atmosferden geçen EMR'yi güçlü bir şekilde yutar. Güneş radyasyonunun yutulması esas olarak ozon, karbondioksit ve su buharı kaynaklıdır. Ozon, ultraviyole spektrumun, kısa dalga boyu kısımlarını ($\lambda < 0.24 \mu\text{m}$) yutar, böylece bu radyasyonun alt atmosfere iletilmesini önler. Karbondioksit, spektrumun orta ve uzak kızılötesi bölgelerindeki radyasyonu yutmada etkilidir (URL-9). Su buharı, gelen uzun dalga kızılötesi ve kısa dalga mikrodalga radyasyonunun çoğunu emer ($22\mu\text{m}$ ve 1m arasında) (URL-2).

Atmosfer seçici olarak belirli dalga boylarındaki enerjiyi iletir. Atmosferin nispeten şeffaf olduğu spektral bantlar, atmosferik pencereler olarak bilinir. Atmosferik pencereler, EM spektrumun görünür kısımda ve kızılötesi bölgelerinde bulunur (URL-9). Radar ve pasif mikrodalga sistemleri 1 mm ile 1 m arasındaki bir pencereden çalışır (URL-8).

3.4. Enerji- Nesne Etkileşimi ve Nesnelerin Spektral İmzası

Yutulma veya saçılmaya uğramadan dünyanın atmosferinden geçen elektromanyetik radyasyon, dünyanın yüzeyine ulaşarak yüzeyi oluşturan farklı materyallerle farklı şekillerde etkileşime girer. Elektromanyetik radyasyonun yutulması, bir fotonun enerjisinin madde tarafından alındığı durumdur. Böylece, elektromanyetik enerji emicinin iç enerjisine, örneğin termal enerjiye dönüştürülür (URL-10).

Dünya'nın yüzeyindeki enerji olayı, dalga boyuna ve yüzey karakteristiklerinin (toprak, bitki örtüsü veya su kütlesi) özelliklerine bağlı olarak yutulur, geçirilir veya yansıtılır (URL-11).

Geçirilme, radyasyonun ölçülebilir bir zayıflama olmadan maddeden geçme olayının gerçekleştiği süreçtir ; madde böylece radyasyona karşı şeffaftır.

Yüzeyde elektromanyetik enerji meydana geldiğinde, gelen enerjinin dalga boyuna göre yüzeyin pürüzlülüğüne bağlı olarak yansiyabilir veya dağılabilir. Yüzeyin pürüzlülüğü ,dalga boyundan azsa yansıma gerçekleşir (URL-10).

Yansıtma, yansıyan enerjinin gelen enerjiye oranıdır ve bu nedenle bir yüzeyden ne kadar radyasyon yansıtıldığına bir ölçüsüdür. Spektral yansıtma ise dalga boyunun bir fonksiyonu olarak yansıyan enerjinin gelen enerjiye oranıdır. Dünya yüzeyinin çeşitli materyalleri farklı spektral yansıtma özelliklerine sahiptir. Spektral yansıtma, bir nesnenin fotoğraflık görüntüsündeki renk veya tondan sorumludur. Ağaçlar yeşil görünür çünkü yeşil dalga boyunu daha fazla yansıtırlar (URL-12).

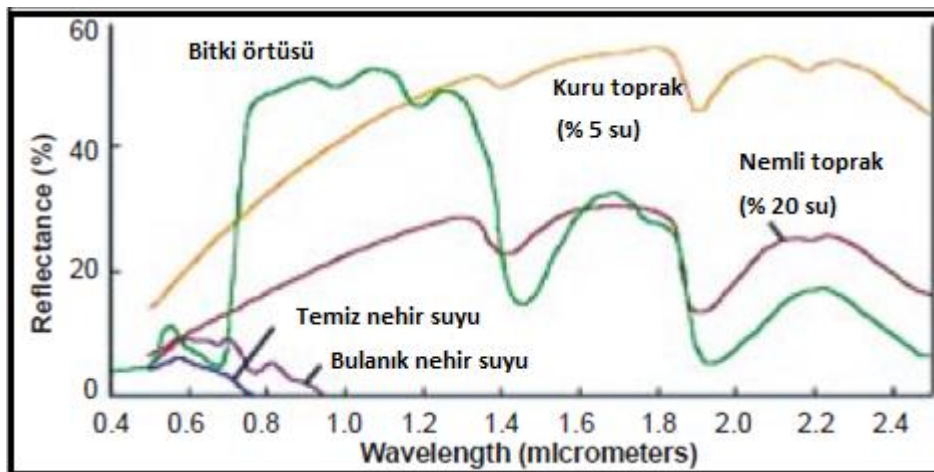
Dalga boyunun bir fonksiyonu olarak bir nesnenin spektral yansıma grafiği spektral yansıtma eğrisi olarak adlandırılır. Spektral yansıtma eğrilerinin konfigürasyonu bize bir nesnenin spektral özellikleri hakkında bilgi verir ve belirli bir uygulama için uzaktan algılama verilerinin elde edildiği dalga boyu bölgesi (bölgelerinin) seçimi üzerinde güçlü bir etkiye sahiptir (URL-8).

Bitki örtüsünün spektral özellikleri dalga boyuna göre değişir (Şekil 3.6.). Klorofil adı verilen yapraklardaki bitki pigmenti, kırmızı ve mavi dalga boylarındaki radyasyonu güçlü bir şekilde yutar, ancak yeşil dalga boyunu yansıtır (URL-9). Yapraklar klorofil içeriğinin maksimumda olduğu yaz aylarında bize "en yeşil" görünür. Sonbaharda, yapraklarda daha az klorofil vardır, bu nedenle kırmızı dalga boylarının daha az emilimi ve orantılı olarak daha fazla yansıması vardır, bu da yaprakların kırmızı veya sarı görünmesini sağlar (URL-10). Yaklaşık 0,7 μ m'de spektrumun görünürden yansıyan kızılötesi kısmına geçerken, sağlıklı bitki örtüsünün yansıması önemli ölçüde artar. Yaklaşık 0.7 ila 1.3 μ m aralığında bir bitki yaprağı, üzerinde meydana gelen enerjinin yaklaşık yüzde 50'sini yansıtır. 0.7 ila 1.3 μ m aralığında bitki yansıması, öncelikle bitki yapraklarının iç yapısından kaynaklanır. Bu yapı bitki türleri arasında oldukça değişken olduğu için, bu aralıktaki yansıma ölçümleri, görünür dalga boylarında aynı görünseler bile, türler arasında ayırım yapmamıza izin verir. Benzer şekilde, birçok bitki stresi bu bölgedeki yansımayı değiştirir ve bu aralıkta çalışan sensörler genellikle bitki örtüsü tespiti için kullanılır. 1.3 μ m'nin ötesinde, bitki

örtüsünde meydana gelen enerji yutulur veya yansıtılır, çok az miktarda enerji geçirilir veya hiç geçirilmez. Yansıtımadaki düşüşler 1,4, 1,9 ve 2,7 μm 'de meydana gelir çünkü yapraktaki su bu dalga boylarında güçlü bir şekilde yutulur (URL-8).

Suyun spektral yansımaları göz önüne alındığında, muhtemelen en ayırt edici özellik yansıyan kızılötesi dalga boylarındaki enerji yutulmasıdır. Uzaktan algılama verileri ile su kütlelerinin yerini belirleme ve tanımlama bu yutulma özelliğinden dolayı yansıyan kızılötesi dalga boylarında en kolay şekilde yapılır. Ancak, su kütlelerinin çeşitli koşulları kendilerini öncelikle görünür dalga boylarında gösterir. Bu dalga boylarındaki enerji / madde etkileşimleri çok karmaşıktır ve birbiriyle ilişkili birkaç faktöre bağlıdır (URL-8). Bir su kütesinin yansıtımadaki değişkenliğini etkileyen faktörler su derinliği, su içerisindeki materyaller ve suyun yüzey pürüzlülüğüdür (Şekil 3.6.) (URL-9). Su, görünür bölge kısa dalga boylarında daha güçlü yansıma nedeniyle mavi veya mavi-yeşil görünür ve kırmızı veya kızılötesi dalga boylarına yaklaştığında ise yutulmadan dolayı daha koyu görünür (URL-10).


Toprak yüzeyi, yeşil ve kırmızı EMR'nin bir kombinasyonu olduğu için insan gözlerine kahverengidir. Enerjinin çoğu ya yutulur ya da yansıtılır ve çok az miktarda enerji topraktan geçirilir. Toprak yüzeyinde, görünür ve IR bölgelerinde dalga boyunun artmasıyla yansıtma seviyesi kademeli olarak artar (URL-11). Toprağın yansıtma özelliklerini belirleyen özellikleri nem içeriği, organik madde içeriği, dokusu, yapısı ve demir oksit içeriğidir. Topraktaki nemin varlığı yansıma oranını azaltır (Şekil 3.6.) (URL-9).



Şekil 3.6. Bitki örtüsü, toprak ve su için spektral yansıtma eğrileri

3.5. Uzaktan Algılamada Görüntü Kaynaştırma (Füzyonu)

Farklı görüntü yöntemlerinden mekânsal ve spektral bilgileri etkili bir şekilde kaynaştırma, uzaktan algılama için oldukça önemli bir araçtır (Vaipoulos ve Karantzalos, 2016).Görüntü kaynaştırma, yüksek çözünürlüklü bir görüntünün geometrik detaylarını düşük çözünürlüklü multispektral bantlarla birleştiren piksel düzeyinde bir füzyon olarak tanımlanabilir (Wald ve ark., 1997; Amro ve ark., 2011; Zheng ve ark., 2017) (Şekil 3.7.).



Şekil 3.7. Pan-sharpened görüntü (URL-12)

Görüntü füzyonu, her iki görüntüden de en iyi özelliklere sahip yeni bir görüntü elde etmek için farklı görüntüleri birleştirir (Kaplan ve Avdan, 2018a). Worldview ve Landsat gibi çoğu Dünya gözlem uydusu, yüksek çözünürlüklü bir pankromatik görüntü ve daha düşük mekansal çözünürlüklü çoklu spektral görüntüler elde eder (Xu ve ark., 2014 ; Kaplan ve Avdan, 2018a), bu yüzden daha yüksek bir mekansal çözünürlüklü

çokbantlı görüntü üretmek için multispektral görüntüleri ve pankromatik görüntüleri birleştirmek gerekir (Kaplan ve Avdan, 2018a).

Tez kapsamında kullanılan Sentinel-2 görüntüleri görünür, yakın kızılötesi (NIR) ve kısa dalga kızılötesi (SWIR) dalga boylarında 13 bandı kapsar. Mekansal çözünürlüğü 10, 20 ve 60 m bantlar içerir. Kırmızı, Yeşil, Mavi ve NIR bantları 10 m uzamsal çözünürlüğe, dört Bitki Örtüsü Kırmızı Kenarı ve iki SWIR bandı 20 m uzamsal çözünürlüğe sahipken, Kıyı aerosolü, Su buharı ve Cirrus bantları 60 m uzamsal çözünürlüğe sahiptir. Bu nedenle Sentinel-2, yüksek çözünürlüklü pankromatik bant sunmaz (Kaplan ve Avdan, 2018a). Ancak, 10 m'lik bantların varlığı, görüntü kaynaştırma yoluyla, daha ayrıntılı mekansal bilgi sağlamak için 20 m'lik bantları 10 m mekansal çözünürlüğe getirmek için kullanılabilir (Wang ve ark., 2016).

Görüntü kaynaştırma işleminin gerçekleştirilmesi amacıyla birçok algoritma geliştirilmiştir. Bu algoritmalar, temel bileşenler analizi (PCA) (Shettigara 1992), yoğunluk-ton-doygunluk (IHS) dönüşümü (Tu ve ark. 2001), Brovey dönüşümü (BT) (Gillespie ve diğerleri 1987), Gram-Schmidt (GS) dönüşümü (Laben ve Brower 2000) en çok kullanılanlar arasındadır (Wang ve ark., 2016). Tez kapsamında kullanılan Arcgis yazılımı ise pan-sharpened görüntü oluşturmak için beş görüntü kaynaştırma yöntemi sunar: yoğunluk-ton-doygunluk (IHS) dönüşümü, Brovey dönüşümü, Esri pan-sharpening dönüşümü, basit ortalama dönüşüm ve Gram-Schmidt spektral bileme yöntemi (URL-13). IHS dönüşümünde, renkli bir MS görüntüsü RGB uzayından IHS renk uzayına dönüştürülür. Yoğunluk (I) bandı pankromatik (PAN) bir görüntüye benzediğinden, füzyonda yüksek çözünürlüklü bir PAN görüntüsüyle değiştirilir. Daha sonra renk tonu (H) ve doyguluk (S) bantlarıyla birlikte PAN üzerinde ters bir IHS dönüşümü gerçekleştirilir, bu da IHS kaynaşmış bir görüntüyle sonuçlanır. Brovey dönüşümünde ise temel prosedür önce her bir MS bandı yüksek çözünürlüklü PAN bandıyla çarpılır ve ardından her ürün MS bantlarının toplamına bölünür (URL-14). Esri pan-sharpening dönüşümü, pan-sharpened sonuç ürünü oluşturmak için bir ağırlıklı ortalama ve ek olarak yakın-kızılötesi bandı kullanır. Multispektral bantların ağırlıkları, multispektral bantların spektral duyarlılık eğrilerinin pankromatik bant ile örtüşmesine bağlıdır. Pankromatik bant ile en büyük örtüşmeye sahip multispektral bant en büyük ağırlığı almalıdır. Pankromatik bantla hiç örtüşmeyen bir multispektral bant, sıfır ağırlığa sahip olmalıdır. Gram-Schmidt dönüşümü, vektör dikeyleştirme için genel bir algoritmaya (Gram-Schmidt dikeyleştirme) dayanmaktadır. Bu algoritma dik olmayan vektörleri (örneğin, 3B uzayda 3 vektör) alır ve daha sonra dik olacak şekilde döndürür.

Gram-Schmidt dönüşümünde ilk adım, MS bantlarının ağırlıklı bir ortalamasını hesaplayarak düşük çözünürlüklü bir pan bandı oluşturmaktır. Daha sonra, bu bantlar, her bandı çok boyutlu bir vektör olarak ele alan Gram-Schmidt dikgenleştirme algoritması kullanılarak ilintisizleştirilir. Simüle edilmiş düşük çözünürlüklü pan bandı, döndürülmemiş veya dönüştürülmemiş ilk vektör olarak kullanılır. Daha sonra düşük çözünürlüklü pan bandı, yüksek çözünürlüklü pan bandı ile değiştirilir ve tüm bantlar yüksek çözünürlükte geri dönüştürülür. Basit ortalama dönüştürme yöntemi, çıktı bandı kombinasyonlarının her birine basit bir ortalama alma denklemi uygular (URL-13).

3.6. Uzaktan Algılamada Görüntü Sınıflandırma

Uzaktan algılama alanındaki görüntü sınıflandırma, sınıflara piksel veya bir görüntünün temel birimlerini atama işlemidir. Uzaktan algılanan verilerde bulunan özdeş piksel gruplarını, pikselleri birbirleriyle ve bilinen kimliğe göre karşılaştırarak, kullanıcının ilgi duyduğu bilgi amaçlı kategorilerle eşleşen sınıflara birleştirmesi muhtemeldir (Gabrya ve Petrakieva, 2004; Perumal ve Bhaskaran, 2010). Sınıflandırma, bir görüntünün piksellerini (nispeten küçük) bir sınıf kümesine kümelemeyi içerir, böylece aynı sınıftaki pikseller benzer özelliklere sahip olur. Görüntü sınıflandırmasının çoğu, arazi örtüsü sınıflarının spektral tepki modellerinin saptanmasına dayanmaktadır. Sınıflandırma, kullanılan bant setindeki arazi örtüsü sınıfları için ayırt edici imzalara ve bu imzaları mevcut olabilecek diğer spektral tepki modellerinden güvenilir bir şekilde ayırt etme yeteneğine bağlıdır (Eastman, 2003; Hasmadi ve ark., 2009).

Uzaktan algılanan verileri sınıflandırmak için birçok farklı yaklaşım vardır. Bununla birlikte, kontrolsüz ve kontrollü sınıflandırma tekniği olmak üzere iki ana başlık altında toplanmaktadır (Hasmadi ve ark., 2009). Kontrollü sınıflandırma, kullanıcının bilinen arazi örtülerinin eğitim alanlarını tanıdığı bir görüntüdeki spektral olarak benzer alanların tanımlanması için bir prosedürdür; sınıflandırma algoritması bu spektral karakteristikleri sınıflandırma için diğer alanlara ayırır. Kontrolsüz sınıflandırma, bir görüntünün, doğrudan kullanıcı rehberliği müdahalesi olmadan, yalnızca görüntü istatistiklerine dayalı olarak bilgisayar işlemesi ile kategorize edilmesini içerir (Castillejo-Gonzalez ve ark., 2009).

3.6.1. Kontrollü Sınıflandırma

Kontrollü sınıflandırma, bilinmeyen kimliğe sahip piksellerin, analist tarafından tanımlanan bilinen bilgi sınıfındaki (eğitim alanları olarak adlandırılır) piksellerin

spektral özelliklerini kullanarak bir sınıflandırma algoritması yoluyla sınıflandırılmasını içerir (Campbell, 2002; Enderle ve Weih, 2005). Bu yaklaşımı sınıflandırmada kullanmanın birçok avantajı vardır. İlk olarak, analistin nihai sınıflandırmada atanacak bilgi kategorileri veya sınıfları üzerinde tam kontrolü vardır. Bu, her ikisi için de aynı sınıfları kullanarak diğer sınıflandırmalarla daha kolay karşılaştırma yapılmasını sağlar (Enderle ve Weih, 2005). İkincisi, eğitim alanlarının seçilmesi süreci ile ortaya çıkan sınıflandırma, bilinen kimliğin imajı üzerindeki belirli alanlara bağlanır. Üçüncüsü, analist spektral sınıfları bilgi sınıflarıyla eşleştirme sorunuyla karşılaşmaz, çünkü bu eğitim alanlarının seçimi sırasında ele alınmaktadır. Son olarak, eğitim verileri, sınıflandırma sürecinde ciddi hataları veya sorunları tespit etmenin bir yolu olarak son sınıflandırma ile karşılaştırılabilir (Campbell, 2002; Enderle ve Weih, 2005).

Kontrollü sınıflandırma kullanımının dezavantajları ve sınırlamaları da vardır. İlk olarak, analist, verilerde bulunmayabilecek eğitim alanlarının ve belirli bilgi sınıflarının seçilmesiyle "verilere bir sınıflandırma yapısı dayatmaktadır" (Campbell, 2002; Enderle ve Weih, 2005). İkincisi, spektral özellikler genellikle sınıflandırma sürecinde örtüşmeye ve belirsizliğe yol açabilen eğitim alanlarının tanımlanmasında kullanılan temel özellikler değildir. Üçüncüsü, eğitim alanlarının seçimi analistin alan hakkında kapsamlı bilgi sahibi olmasını ve kontrolsüz sınıflandırma için gerekli olmayan zaman ve kaynak yatırımını gerektirmektedir. Son olarak, görüntüde bulunan benzersiz sınıflar, sınıfların ve eğitim alanlarının seçimi sırasında analist tarafından göz ardı edilebilir (Enderle ve Weih, 2005).

3.6.2. Kontrolsüz Sınıflandırma

Kontrolsüz sınıflandırmada, uzaktan algılanan bir veri setini alacak ve multispektral veya hiperspektral alanda önceden belirlenmiş sayıda istatistiksel kümeyi bulan bir algoritma seçilir. Bu kümeler her zaman gerçek arazi örtüsü sınıflarına eşdeğer olmasa da, bu yöntem çalışma sahasında zemin örtüsü hakkında önceden bilgi sahibi olmadan kullanılabilir (Nie ve ark., 2001; Hasmadi ve ark., 2009).

Kontrolsüz sınıflandırma, bir sınıflandırma algoritması vasıtasıyla görüntü spektrumlarının benzer spektral özelliklere dayalı doğal gruplara ayrılmasını ve bu grupların analist tarafından bilgi sınıflarına tahsis edilmesini içerir. Bu yaklaşımı sınıflandırmada kullanmanın üç temel avantajı vardır. İlk olarak, görüntü piksellerinin başlangıçta ayrılması için sınıflandırılan alanın kapsamlı bilgisi gerekli değildir. İkincisi, analistin sınıflandırma sürecinde çok fazla karar vermesi gerekmediği için

insan hatası için fırsat yoktur. Üçüncü olarak, kontrollü bir sınıflandırmada gözden kaçırılacak sınıflar kontrolsüz sınıflandırmada tanınacaktır (Enderle ve Weih, 2005).

Kontrolsüz sınıflandırma kullanımının dezavantajları ve sınırlamaları da vardır.

İlk olarak, sınıflandırma işlemiyle tanımlanan, spektral olarak homojen olan doğal gruplar, ilgilenilen bilgi sınıflarına uymayabilir. İkincisi, analistin sınıflandırma sürecinde seçilen sınıflar üzerinde sınırlı bir kontrolü vardır ve spektral sınıfların doğal grupları ile istenen bilgi sınıflarının sınıflamaları arasındaki ilişkiler her zaman doğrudan ilişkili değildir (Enderle ve Weih, 2005).

3.7. Sınıflandırma Doğruluğu

Uzaktan algılama ile arazi örtüsü haritalama çalışmasında, uzaktan algılama sonuç ürünün değerlendirilmesi için doğruluk değerlendirmesi önemlidir. Değerlendirmenin amacı, ürün üzerinde sınıflandırma kalitesi ve kullanıcı güvenini garanti altına almak için önemlidir (Foody, 2001; Hasmadi ve ark., 2009).

Uzaktan algılamada önemli bir endişe, tahmini harita ile yer-doğruluk haritası arasındaki çakışmayı ölçmektir. Herhangi bir öznel tahminden kaçınmak için, her sınıfın sınıflandırılmış piksellerinin yüzdesini doğrulanmış gerçek doğruluk sınıfıyla karşılaştırarak yöntemin doğruluğunu belirleyen ve daha sonra çalışılan sınıflar arasındaki doğru değerlendirmeyi ve hataları belirten sayısal bir karışıklık matrisi analizi kullanılır (Congalton, 1991; Castillejo-Gonzalez ve ark., 2009).

Bir görüntü sınıflandırmasını değerlendirirken, dikkate alınabilecek iki doğruluk payı vardır. Birincisi, sınıflandırılmış görüntü ile referans veriler arasındaki belirli uyuşmalarda aralarındaki uyuşmayı incelemeyen, genel uyuşmaya bakan yerinde olmayan doğruluktur. Bir sınıflandırmayı değerlendirmek için yalnızca sahaya özgü olmayan doğruluğa güvenmek, sınıflandırılmış görüntü ile referans verileri arasındaki sınıflandırmalardaki anlaşmazlıktan kaynaklanan hataları ortaya çıkarabilir. İkinci doğruluk biçimi, sınıflandırılmış görüntüdeki belirli konumlardaki sınıflar ve referans verileri arasındaki anlaşmayı inceleyen yere özgü doğruluktur. Bu inceleme, belirli konumlar için referans verilerinde bir alanın ne olduğunu ve o alanın nasıl sınıflandırıldığını karşılaştırmak için bir hata matrisi (Şekil 3.8) (bir karışıklık matrisi veya beklenmedik durum tablosu olarak da bilinir) aracılığıyla yapılır.

Hata matrisini kullanarak sahaya özgü doğruluk değerlendirmesi için, sınıflandırma doğruluğunun üç temel ölçüsü vardır: genel sınıflandırma doğruluğu,

üreticinin doğruluğu ve kullanıcının doğruluğu. Genel sınıflandırma doğruluğu, sınıflandırılan alanın tamamından ne kadar alanın doğru olarak sınıflandırıldığıнын ölçüsüdür. Hata matrisinden, genel sınıflandırma doğruluğu, köşegenlerin toplamının bütüne bölünmesiyle elde edilir. Üreticinin doğruluğu her sınıf için hesaplanır ve belirli bir sınıfın bu sınıflamanın üreticisi tarafından ne kadar iyi sınıflandırıldığıнын bir göstergesidir. Bu doğruluk çoğunlukla üretici tarafından sınıflandırmanın ne kadar iyi gerçekleştirildiğini değerlendirmek için bir araç olarak kullanılır. Hata matrisinden, her sınıf için üreticinin doğruluğu, doğru sınıflandırılmış piksellerin sınıfa olan referans veri piksellerinin sayısına (toplam sütun tarafından belirlendiği şekilde) bölünmesinin sonucudur. Kullanıcının doğruluğu da her sınıf için hesaplanır ve görüntü sınıflamasında belirli bir sınıfa atanan alanların gerçekte "zeminde" o sınıfa ne sıklıkta ait olduğunu gösterir. Bu doğruluk, sınıflandırma kullanıcıları için daha önemlidir, çünkü bu, sınıflandırılan görüntünün zemindeki gerçek durum için ne kadar doğru olduğunu gösterir. Hata matrisinden, her sınıf için kullanıcının doğruluğu, belirli bir sınıftaki doğru sınıflandırılmış piksellerin, sınıflandırılan görüntüdeki sınıfa ait toplam piksel sayısına bölünmesiyle elde edilir (toplam satır tarafından belirlenir) (Enderle ve Weih, 2005).

	A	B	C	D	Toplam
A	n_{AA}	n_{AB}	n_{AC}	n_{AD}	n_{A+}
B	n_{BA}	n_{BB}	n_{BC}	n_{BD}	n_{B+}
C	n_{CA}	n_{CB}	n_{CC}	n_{CD}	n_{C+}
D	n_{DA}	n_{DB}	n_{DC}	n_{DD}	n_{D+}
Toplam	n_{+A}	n_{+B}	n_{+C}	n_{+D}	n

olmak üzere, üretici ve kullanıcı doğruluğu;

Doğruluk yüzdesi :
$$\frac{\sum_{k=1}^q n_{kk}}{n} * 100$$

Şekil 3.8. Hata Matrisi (Sertel ve diğ., 2011, Çelik,2015)

3.8. Uzaktan Algılamada Oran Görüntüleri

Görüntü dönüşümü, tek bir çok bantlı görüntüden veya farklı zamanlarda elde edilen aynı alanın iki veya daha fazla görüntüsünden birden fazla veri bandının değiştirilmesini içerir. Bu süreçte, yeni bir görüntü elde etmek için ham bir görüntü veya birkaç görüntü kümesi bazı matematiksel işlemlere tabi tutulur. Sonuç olarak, iki veya daha fazla kaynaktan üretilen yeni elde edilen dönüştürülmüş görüntü, belirli öznelikleri veya özellikleri orijinal haldeki görüntülerinden daha iyi vurgular. Görüntü dönüştürme teknikleri, benzer türde bilgiye sahip bantların daha az banda sıkıştırılması ve aynı zamanda insan gözüyle daha yorumlanabilir yeni veri bantlarının çıkarılması için yararlıdır.

Görüntü dönüştürme tekniklerinden biri, görüntü verilerine basit aritmetik / mantıksal işlemler uygulamaktır. Toplama, çıkarma, çarpma ve bölme işlemlerinin aritmetik işlemleri aynı coğrafi alandaki iki veya daha fazla görüntü üzerinde gerçekleştirilebilir. Görüntü bölünmesi veya bant oranı yaygın olarak kullanılan bir aritmetik işlemdir. Bant oranı, bir görüntü bandındaki pikseller için DN'yi diğer görüntü bandındaki DN'lere bölerek özellikler arasındaki kontrastı artırmak için uygulanan bir görüntü dönüştürme tekniğidir. Bant oranlama tekniği genellikle çokbantlı bir görüntü üzerine uygulanır.

Bant oranı ve çıkarma tekniklerinin kombinasyonu kullanılarak birçok uygulama için yaygın olarak kullanılan çeşitli endeksler geliştirilmiştir. Birkaç endeksten normalleştirilmiş fark bitki örtüsü indeksi (NDVI) gibi vejetasyon indeksleri daha popülerdir (Anand, 2017).


3.8.1. Normalleştirilmiş Fark Bitki Örtüsü İndeksi (NDVI)

Vejetasyon indeksi (VI), uzaktan algılama bantlarının bir kombinasyonu tarafından üretilen bir sayıdır ve belirli bir görüntü pikselindeki bitki örtüsü miktarı ile bir ilişkisi olabilir. İndeks, klorofil konsantrasyonuna ve fotosentetik aktiviteye duyarlı birkaç spektral bant kullanılarak hesaplanır. Vejetasyon indeksleri kavramı, uzaktan algılanan spektral bantların bazı cebirsel kombinasyonlarının bize bitki örtüsü hakkında bir şeyler söyleyebileceğine dair, deneylerle elde edilen bilgilere dayanmaktadır. Bilimsel literatürde 200'den fazla VI'den bahsedilmiştir, ancak bunlardan sadece birkaçı sistematik olarak çalışılmıştır ve biyofiziksel anlamı vardır. VI'ların her biri belirli bir bitki örtüsü özelliğini vurgulamak için tasarlanmıştır (Anand, 2017).

Yıllık mahsul üretim seviyelerini tahmin etmek için kullanılan tekniklerden biri vejetasyon büyümesinin uzaktan algılama ile izlenmesidir. Bu amaçla kullanılan çeşitli vejetasyon indekslerinden en yaygın olarak kullanılanı Normalleştirilmiş Fark Bitki Örtüsü İndeksi(NDVI)'dir (Koller, 2003; Wall ve ark., 2008). NDVI, elektromanyetik spektrumun görünür ve NIR bantlarını kullanan sayısal bir göstergedir. Temel olarak uzaktan algılama ölçümlerini analiz etmek ve hedefin 'yeşilliğini' değerlendirmek için kullanılır. Multispektral uydu sensörlerinin çoğu NDVI'ı hesaplamak için kullanılan görünür ve kızılötesi kanallara sahip olduğu için NDVI, uzaktan algılama uydusundan bitki örtüsünü incelemek için çok önemli bir araçtır. NDVI, aşağıdaki formülü uygulayarak, kırmızı bant ve kızılötesi bant kullanılarak hesaplanabilir:

$$NDVI = (NIR - Kırmızı) / (NIR + Kırmızı)$$

Bitki yapraklarındaki klorofil pigmenti, fotosentezde kullanılmak üzere görünür ışığı (0.4 ila 0.7 μm) güçlü bir şekilde emer. Yaprakların hücre yapısı ise NIR ışığını güçlü bir şekilde yansıtır (0.7 ila 1.1 μm). Bitkilerin EM spektrumundaki davranışlarını bildiğimiz için, bitki örtüsü bilgisine (NIR ve kırmızı) en duyarlı uydu bantlarına odaklanarak NDVI bilgilerini türetebiliriz (Şekil 3.9.). Genel olarak, NIR dalga boylarında görünür dalga boylarına göre çok daha fazla yansıyan radyasyon varsa, o pikseldeki bitki örtüsünün yoğun olması muhtemeldir ve bazı orman türlerini içerebilir. Görünür ve NIR dalga boylarının yoğunluğunda çok az fark varsa, bitki örtüsü muhtemelen seyrek ve otlak, tundra veya çölden oluşabilir (Anand, 2017).



Şekil 3.9. Sağlıklı bitki örtüsü, görünür ışığın çoğunu emer ve NIR ışığını yansıtır. Sağlıksız veya seyrek bitki örtüsü NIR ışığını görünür ışığa göre çok daha az yansıtır. (Anand, 2017)

NDVI değerleri -1 ile 1 arasında değişen birimsiz bir endekstir. Sağlıklı bitki örtüsü yüksek pozitif değerlere sahipken, çıplak toprak, su, kar, buz veya bulutlar sıfır veya negatif NDVI değerlerine sahiptir. Tipik olarak sağlıklı bitki örtüsünün NDVI değerleri, büyüme mevsiminin başında bitki örtüsü arttıkça artar, büyüme mevsiminin ortasında zirveye ulaşır ve sezon sona erdiğinde azalır (Mkhabela ve ark., 2005; Turvey ve Mclaurin, 2012).

4. REKOLTE TAHMİNİ

4.1 Rekolte Tahmini Uygulama Alanları ve Önemi

Bölgesel, ulusal ve uluslararası ölçeklerde ürün veriminin doğru ve gerçek zamanlı tahmini, hem gelişmekte olan hem de gelişmiş ülkelerde giderek daha önemli hale gelmektedir. Özellikle, mahsul verimi tahmini, tarım politikaları ve tarımda karar vermeyi (örneğin gıda kıtlığının yönetimi) desteklemede önemli bir rol oynayabilir (Moriondo ve ark., 2007). Büyüme sezonundaki güvenilir verim tahmini, gelişmiş planlama, tahıl üretimi yönetimi, işleme ve pazarlamayı mümkün kılacaktır (Dente ve ark., 2008). Sonuç olarak, hasat öncesi doğru verim tahminleri, yetiştiriciden endüstri düzeyine kadar karar verme sürecini iyileştirmek için çok önemlidir (Robson ve ark., 2016).

Doğru verim tahmini, yetiştiricilerin meyve inceltme yoğunluğu ve hasat için işgücünün boyutu konusunda daha iyi kararlar vererek meyve kalitesini iyileştirmesine ve işletme maliyetini düşürmesine yardımcı olur. Yöneticiler, paketleme ve depolama için optimize edilmiş bir kapasite planlamasına sahip olmak için tahmin sonuçlarını kullanabileceği için paketleme endüstrisine de fayda sağlar (Wang ve ark., 2012)

N(Azot) yönetimini optimize etmek ve mevzuata uygunluğu sağlamak için, üreticiler tüm kaynaklardan (gübre, kompost ve gübreler, sulama suyu azotu) elde edilebilen N'yi dikkate alarak N'yi her üretim birimindeki tahmini verime göre uygulamalıdır. Bu nedenle verim tahmini N yönetimi için kritiktir. Ayrıca, yetiştiricilerin mahsulün hasat, işleme ve nakliyesi için planlar yapmalarına yardımcı olabilir (Zarate-Valdez ve ark., 2015 ; Zhang ve ark., 2019). Bu nedenle, mahsul verimini doğru bir şekilde tahmin etmek, örneğin çiftlikteki girdilerin (sulama suyu, gübreler) ve diğer kaynakların (makine, işgücü) optimal kullanımı üzerindeki etkisi sayesinde ekoloji, ekonomi ve insan toplumu için geniş etkilere sahiptir (Carletto ve ark., 2015; Hoffman ve ark., 2015 ; Zhang ve ark., 2019). Elma ağacı çok sayıda çiçek ürettiğinde, çiçek sayısını azaltmak için kimyasal veya makine inceltme uygulanır. Dahası, bir elma bahçesinde çiçek yoğunluğunun mekansal bilgisi, gübreleme ve hasat konusunda da önemli bir katkı sağlayabilir. Mekansal değişkenlik hakkındaki bilgilerle çiftçi bu bilgileri daha fazla ihtiyaç duyulan yerlerde gübre kullanmaya karar vermek

için kullanılabilir ve daha az miktarda meyve taşıyan ağaçlarda daha az ihtiyaç duyulan yerlerde daha az gübre kullanılabilir (Tubau Comas ve ark., 2019).

Meyve ağaçlarında uygun modeller kullanılarak verimin tahmini özellikle sigorta açısından önemlidir. Kış veya don yaralanması gibi kayıplar meyve bahçelerinde ciddi hasarlara neden olabilir ve Üreticilerin garanti altına alınması için, genellikle sonbaharda yaprak dökülmesinden hemen sonra ve ayrıca don olayından sonra gelecek yılın mahsulünü tahmin edebilmek gerekecektir (Hassani ve ark., 2014).

Tercihen verim, mahsul gelişimi sırasında çeşitli dönemlerde tahmin edilir, ancak çok büyük işçilik maliyeti ve zaman gerektirir. Yetiştiriciler için kesin, düşük maliyetli verim tahmini, özellikle büyüme mevsiminde zamanında yapılabiliriyorsa önemlidir. Portakal suyunun hasattan sonraki kırk sekiz saat içinde işlenmesi gerektiğinden, portakal suyu üreticilerinin, meyve suyu tesislerinin zaman kısıtlamaları göz önüne alındığında tam kapasitede çalışabilmelerini garanti etmek için tedarikçilere doğru verim tahminleri vermeleri gerekmektedir. Buna ek olarak, daha doğru verim tahminleri, çiftçilerin hasat işçiliği ve diğer lojistik ihtiyaçları için daha kesin bir şekilde planlama yapmalarına olanak sağlayacaktır (Malik ve ark., 2016).

4.2. Rekolte Tahmininde Uzaktan Algılamanın Rolü

Meyve bahçelerinde verim tahmini ve haritalama, kaynakların verimli kullanımını kolaylaştırdığı ve birim alan ve zaman başına getiriye artırdığı için yetiştiriciler için önemlidir (Bargoti ve Underwood, 2017). Özellikle, daha küçük alanlarda mahsul veriminin doğru bir şekilde tahmin edilmesi, mahsul yetiştiricileri ve toptancılardan talep edilmiştir (Bellow, 2007; Choi ve ark., 2015) Verim tahmini aynı zamanda yetiştiricinin hasat lojistiği, mahsul depolama ve satışlarını önceden planlamalarını sağlar (Bargoti ve Underwood, 2017) .

Üretim değişkenleri ve biyofiziksel değişkenlerin geleneksel yerinde ölçümleri zaman alıcıdır ve yoğun emek gerektirir. Bu, bahçeler içinde ve arasında yüksek mekansal ve zamansal değişkenliği açıklamak için yetersiz olan sınırlı örnek ve tekrarlarla sonuçlanır (Aggelopoulou ve ark., 2009; Perry ve ark., 2009; Beek ve ark., 2015). Uzaktan algılamanın bahçecilik için tahribatsız, zaman açısından verimli ve maliyet açısından faydalı alternatifler sağlayabileceği kabul edilmektedir (Dorigo ve ark., 2007; Beek ve ark., 2014; Beek ve ark., 2015).

Mahsul verimi tahmini için uzaktan algılama uygulaması çoğunlukla yıllık mahsuller için geliştirilmiştir (Thenkabail ve ark., 1994; Zarco-Tejada ve ark., 2005;

Beek ve ark., 2015). Uzun ömürlü olanlar için, uzaktan algılama yoluyla üretim özelliklerinin tahmini daha önce narenciye (Ye ve ark., 2007; Somers ve ark., 2010) , elma (Best ve ark., 2008; Aggelopoulou ve ark., 2009) , şeftali (Sepulcre-Canto ve ark., 2007) , zeytin (Sepulcre-Canto ve ark., 2007) ve asma (Serrano ve ark., 2012) gibi farklı meyve mahsulleri için araştırılmıştır. Bu çalışmalarda, odak noktası daha çok toplam verimin tahminine dayanmaktadır, çünkü daha yüksek verimler ana ilgi alanı olmuştur. Bununla birlikte, son yıllarda, meyve üretim sistemlerine odaklanmak, daha kaliteli meyveler için daha fazla ödeme yapma istekliliği nedeniyle kaliteye ilişkin üretim özelliklerine doğru kayılmıştır (Gallardo ve ark., 2011; Beek ve ark., 2015).


Kanopi boyutu ve mahsul canlılığı mahsul veriminin kilit belirleyicileridir. Uydu uzaktan algılama, kanopi yapısını ve bitki canlılığını farklı zaman ölçeklerinde orta ila yüksek uzamsal çözünürlüklerde karakterize etmeyi mümkün kılar ve bu nedenle ürün verimi analizi için büyük bir potansiyele sahiptir (Ferencz ve diğerleri, 2004; Rembold ve diğerleri, 2013; Johnson, 2014; Sibley ve ark., 2014; Guan ve ark., 2017; Zhang ve ark., 2019).Örneğin, Orta Amerika Birleşik Devletleri'ndeki ilçe düzeyinde mısır ve soya fasulyesi verimini tahmin etmek için MODIS verilerinden elde edilen çoklu bitki örtüsü indeksleri (VI) kullanılmıştır (Bolton ve Friedl, 2013; Zhang ve ark., 2019).

5. UYGULAMA

5.1. Çalışma Alanı ve Veriler

5.1.1. Çalışma Alanı

Çalışma sahası olarak ülkemizin tarımsal üretiminde önemli bir yeri olan Doğu Anadolu bölgesinin, dünya çapında kayısının en büyük üreticisi konumunda olan Malatya ili Battalgazi ve Yeşilyurt ilçeleri seçilmiştir (Şekil 5.1.). Çalışma alanı olarak seçilen Malatya ili Merkez ilçelerinden olan Battalgazi ilçesi kayısı üretiminin yoğunluklu olarak yapıldığı ilçelerin başında gelmektedir. Malatya ili yüzölçümü 12.313 km² 'dir. Malatya ilinde 425.450 hektarlık tarım arazisi bulunmakta olup bu arazilerin 218.557 hektarlık bölümü sulanabilir arazi özelliği taşımaktadır (URL-15).



Şekil 5.1. Çalışma alanı

5.1.2. Veriler

5.1.2.1. Uydu Görüntüleri

Kayısı ekili alanların tespiti amacıyla yapılan sınıflandırma işlemi için Avrupa Uzay Ajansı(ESA) tarafından ücretsiz erişim imkanı sunulan Sentinel-2 verisi kullanılmıştır.

Avrupa Uzay Ajansı tarafından Sentinel uydusunun geliştirilmesiyle birlikte Yeryüzü Gözlemi için yeni fırsatlar doğdu. Geliştirilen bu yapı, bilim camiası için yüksek operasyonel yetenek, uzun vadeli süreklilik, sensörlerin üstün kalibrasyonu ve çeşitli algılama yöntemleri ve ürünleri sağlar (Malenovsk ve ark., 2012; Clerici ve ark., 2017). Sentinel-2 misyonu, aynı yörüngede 705 km yükseklikte çalışan, birbirlerine 180 °de fazlanmış ve yörünge eğimi 98,5 ° olan Sentinel-2A (2015 yılında açılan) ve Sentinel-2B (2017 yılında açılan) uydularından oluşur. (Szostak ve ark., 2018).

Programın temel hedeflerine göre, Sentinel-2 misyonu, Landsat ve SPOT görevlerinin veri sürekliliği ve geliştirilmesi için tasarlanmıştır. Sentinel-2 uydusu -56 ° ile 84 ° enlemleri arasındaki alanları kapsamaktadır (Wang ve ark., 2016). Sentinel-2 sensörleri küresel yüzeyde, yüksek tekrar ziyaret süresiyle ve elektromanyetik spektrumun optik NIR, SWIR bölümlerinde 13 bant ile 290 km'yi kapsayan geniş bir görüş alanı ile radyometrik ve geometrik üstünlüklü çok bantlı yüksek mekânsal çözünürlüklü görüntüler sunar (Drusch ve ark., 2012; Clerici ve ark., 2017). Tekrar ziyaret süresi bir uydu için 10 gün ve iki uydu için 5 gündür (Szostak ve ark., 2018).

İnce uzamsal çözünürlük, küresel kapsama ve (nispeten) ince zamansal çözünürlük, Sentinel-2 verilerini uzaktan algılamaya dayanan geniş bir uygulama yelpazesi için harika bir yardımcı program haline getirir (Wang ve ark., 2016). Ayrıca, Sentinel veri dağıtımı, ürünlerin çoğu için tam ve açık bir erişim politikasının temel avantajı ile desteklenmektedir (Belward ve Skøien, 2015; Clerici ve ark., 2017).

Sentinel-2,10 ile 60 metre arası bir çözünürlükte uydu görüntüleri sunar (Drusch ve ark., 2012; Kaplan ve Avdan, 2018b). Görünür ve Yakın kızılötesi bantlar 10 metre mekânsal çözünürlük, dört Bitki Örtüsü Kırmızı Kenar ve iki Kısa dalga kızılötesi bant 20 metre mekânsal çözünürlüğe sahipken , kıyı aerosolü, su buharı ve sirus bantları 60 metre mekânsal çözünürlüğe sahiptir (Selva ve ark.,2015 ; Kaplan ve Avdan, 2018b). Aynı sahneyi kapsayan 10 m bantının varlığı, daha ayrıntılı uzamsal bilgi sağlamak için

20 m bandını 10 m uzamsal çözünürlüğe indirmek için mükemmel fırsatlar sunar (Wang ve ark., 2016).

Sentinel-2 verileri esas olarak bitki örtüsünün, toprak ve su örtüsünün, iç su yollarının ve kıyı alanlarının izlenmesi dahil olmak üzere küresel kara hizmetlerini desteklemeyi amaçlamaktadır (Wang ve ark., 2016). Başka bir deyişle, Sentinel-2'nin karakteristik kombinasyonu, bölgesel ve küresel ölçekte toprak örtüsü karakterizasyonu ve haritalanması için oldukça iyi bir potansiyele sahiptir (Clerici ve ark., 2017).


Sentinel-2 bantlarının spektral özellikleri Tablo 5.1'de gösterilmiştir.

Tablo 5.1. Sentinel-2 spektral bantları (Zhang ve ark., 2017)


Sentinel-2 Bantları	Orta Dalga Boyu (μm)	Çözünürlük (m)
Bant-1 Kıyı Aerosol	0,443	60
Bant-2 Mavi	0,490	10
Bant-3 Yeşil	0,560	10
Bant-4 Kırmızı	0,665	10
Bant-5 Yakın Kızılötesi	0,705	20
Bant-6 Yakın Kızılötesi	0,740	20
Bant-7 Yakın Kızılötesi	0,783	20
Bant-8 Yakın Kızılötesi	0,842	10
Bant-8A Yakın Kızılötesi	0,865	20
Bant-9 Su Buharı	0,945	60
Bant-10 Kısa Dalga Kızılötesi (Cirrus)	1,375	60
Bant-11 Kısa Dalga Kızılötesi	1,610	20
Bant-12 Kısa Dalga Kızılötesi	2,190	20

5.1.2.2. Eğitim ve Test verileri

Çalışmada uydu görüntülerinin sınıflandırılması aşamasında kullanılmak amacıyla Qgis yazılımında yüksek çözünürlüklü Google satellite hybrid görüntülerinden yararlanılarak Battalgazi ve Yeşilyurt ilçelerini uygun özelliklerde tanımlayan rastgele seçilen noktalardan eğitim ve test verisi oluşturulmuştur. Sınıflandırma işleminde kullanılmak için 110 poligondan oluşan, kayısı bahçeleri ve 91 poligondan oluşan diğer sınıflar olmak üzere iki sınıf için eğitim verisi hazırlanmış olup ayrıca sınıflandırma sonrası doğruluk analizinde kullanılmak üzere kayısı ve diğer olmak üzere iki sınıf için de sırasıyla 113 ve 88 adet poligondan oluşan test verisi hazırlanmıştır. Eğitim ve test verileri sırasıyla Şekil 5.2. ve Şekil 5.3.'te gösterilmiştir.



Şekil 5.2. Eğitim verisi



Şekil 5.3. Test verisi

5.1.2.3. Rekolte tahmin verileri

Çalışmada rekolte tahmini aşamasında istatistiksel hesaplamalarda yararlanmak amacıyla Malatya Ticaret ve Sanayi Odası'nın rekolte tahmin verileri kullanılmıştır. 2018 yılı rekolte tahmin verileri Şekil 5.4.'te, 2019 yılı rekolte tahmin verileri Şekil 5.5.'te gösterilmiştir.

MALATYA İLİ 2018 YILI TAHMİNİ KAYISI REKOLTESİ						
İLÇE ADI	Toplam Meyve Veren Ağaç Sayısı (Adet)	Ağaç Başına Ortalama Verim (Kg)	Toplam Yağ Kayısı Üretimi (Ton)	Yağ Olarak Tüketilecek Kayısı Miktarı (Ton)	Kurutulmaya Ayrılacak Kayısı Miktarı (Ton)	Elde Edilecek Kuru Kayısı Miktarı (Ton)
AKÇADAG	1.296.000	50	64.800	9.720	55.080	13.434
ARAPGİR	13.600	40	544	82	462	92
ARĞUVAN	121.182	55	6.665	1.000	5.665	1.382
BATTALGAZI	1.129.000	60	67.740	10.181	57.559	13.709
DARENDE	1.200.800	50	60.030	9.005	51.025	12.445
DOĞANŞEHİR	448.700	55	24.678	3.702	20.976	5.116
DOĞANYOL	189.100	70	13.237	1.986	11.251	2.679
HEKİMHAN	771.000	30	23.130	8.252	13.878	3.555
KALE	177.250	30	5.318	1.329	3.989	1.194
KULUNCAK	352.750	50	17.638	1.610	16.028	2.225
PUTURGE	201.750	60	12.105	2.421	9.684	3.346
YAZIHAN	876.900	70	61.383	7.107	54.276	9.589
YEŞİLYURT	1.044.000	55	57.420	8.813	48.607	11.621
İL TOPLAMI	7.826.932	53	401.363	65.987	335.376	80.818

KOMŞU İLÇELER			
İLÇE ADI	Yağ Üretimi (Ton)	Kurutulmaya Ayrılan (Ton)	Kuru Kayısı Miktarı (Ton)
ELBİSTAN	26.000	21.000	7.000
GÜRLÜN	16.440	6.000	1.500
TOPLAM	36.440	27.000	8.500

Not: İlimiz genelinde heyet olarak yaptığımız çalışmalar sonucunda tahmini kayısı rekoltesi bu değerler üzerinden tespit edilmiştir. 2-3-4 Mayıs ve 16-23 Nisan 2018 tarihlerinde multiaktif bölgelerde meydana gelen zıval dolusunda bazı bölgelerde ağaçların ekimden dolayı, ürün kayıma neden olduğu tespit edilmiştir. 1-20 Mayıs 2018 tarihleri arasında meydana gelen dolu zarar nedeniyle meyvede kalite ve ürün kaybı tespit edilmiştir. Ayrıca Mayıs 2018 ayında meydana gelen ağır yağışlar nedeniyle yaprak dökme (pil) hastalığı nedeniyle de kalite ve ürün kaybı olmuştur. Elazığ ili Baskil İlçe Gıda Tarım ve Hayvancılık Müdürlüğü tespit çalışması yapılmadığından kayısı miktarı verilmemiştir. Elde edilecek kuru kayısının yaklaşık % 30 (24.000 ton) düşük kalitede, % 70'i (56.818 ton) ise yüksek kaliteli kayısı olacaktır tahmin edilmektedir.

HAZIRLAYANLAR

Yusuf KARAKUŞ
Kayısı Araştırma

Bülent KOÇYİĞİT
Ticaret Borsası

Merdan CEMİRTAŞ
Tic. ve San. Odası

Şahin ÇELİK
G.T.H.B. İl Müdürlüğü

KONTROL EDEN
24.05.2018
Şevket BAŞYİĞİT
KTV. Şb. Müdürü

ONAYLAYAN
.../05/2018
Tahir İMCEZ
İl Müdürü

Şekil 5.4. 2018 yılı rekolte tahmin verileri (URL-16)

MALATYA İLİ 2019 YILI TAHMİNİ KAYISI REKOLTESİ						
İLÇE ADI	Toplam Meyve Veren Ağaç Sayısı (Adet)	Ağaç Başına Ortalama Verim (Kg)	Toplam Yağ Kayısı Üretimi (Ton)	Yağ Olarak Tüketilecek Kayısı Miktarı (Ton)	Kurutulmaya Ayrılacak Kayısı Miktarı (Ton)	Elde Edilecek Kuru Kayısı Miktarı (Ton)
AKÇADAG	1.362.000	50	68.100	8.853	59.247	14.812
ARAPGİR	14.160	35	496	90	406	112
ARĞUVAN	116.184	55	6.390	836	5.554	1.438
BATTALGAZI	1.147.250	66	75.716	7.572	68.144	17.037
DARENDE	1.219.800	58	70.737	7.074	63.663	15.916
DOĞANŞEHİR	451.000	36	16.236	1.579	14.657	3.552
DOĞANYOL	180.100	80	14.408	1.521	12.887	3.422
HEKİMHAN	780.000	15	11.700	1.185	10.515	2.866
KALE	179.200	85	15.232	1.165	14.067	2.821
KULUNCAK	400.850	25	10.021	1.007	9.014	2.255
PUTURGE	204.111	47	9.593	959	8.634	2.108
YAZIHAN	876.900	57	50.003	3.858	46.145	9.681
YEŞİLYURT	1.048.400	55	57.662	5.785	51.877	12.974
İL TOPLAMI	7.799.755	60	391.792	41.222	350.570	87.642

KOMŞU İLÇELER			
İLÇE ADI	Yağ Üretimi (Ton)	Kurutulmaya Ayrılan (Ton)	Kuru Kayısı Miktarı (Ton)
BASKIL	0	0	0
ELBİSTAN	0	0	0
GÜRLÜN	7.020	3.000	750
TOPLAM	7.020	3.000	750

Not: İl genelinde heyet olarak yaptığımız çalışmalara göre tahmini kayısı rekoltesi bu değerler üzerinden tespit edilmiştir. Kayısının yoğun olarak yetiştirildiği bazı bölgelerinde 23-24 Mart tarihlerinde, donla bağlı olarak bazı bölgelerde ise 21-22 Nisan tarihlerinde kar yağışı ve atkisinde soğuklarla beraber zıval dolusu olarak kalite kaybı meydana gelmiştir. Ayrıca 9-14 Nisan tarihlerinde lokal dolu yağışlarına dolayı yağışlarla ilgili olarak bir çok bölgede çiçeklerde donlama problemi/kayımları ağaçlarında meydana geldiği görülmüştür. 3-Kayısı değer kayısı yetiştirildiği yapılan çevre ilçelerinde Elbistan ve Baskil ilçelerinde tahmini rekolte alınmış ancak herhangi bilgi verilmemişinden dolayı geçen ilçe tarifi dışı edilmiştir.

HAZIRLAYANLAR

Hakan GÜRBÜZ
Kayısı Araştırma

Hulusi ÖZDEMİR
Kayısı Üretimi

Bülent KOÇYİĞİT
Ticaret Borsası

Merdan DEMİRTAŞ
Tic. ve San. Odası

Necdet CAMBURAR
Tarım ve Orman İl Müdürlüğü

KONTROL EDEN
28.05.2019
Şevket BAŞYİĞİT
KTV. Şb. Müdürü

ONAYLAYAN
28.05.2019
Tahir İMCEZ
İl Müdürü


Şekil 5.5. 2019 yılı rekolte tahmin verileri (URL-16)

5.2. Yöntem

5.2.1. Görüntülerin İyileştirilmesi

Kayıpsı ekili alan tespiti amacıyla yapılan sınıflandırma işlemi için 2018.09.15 tarihli Sentinel-2B verisi kullanılmıştır. Çalışmada kullanılan Sentinel-2 verileri Copernicus Veri Merkezi'nden (<https://scihub.copernicus.eu>) ücretsiz olarak indirilmiştir. Arcgis yazılımı kullanılarak, elde edilen uydu görüntüsünün 20 m çözünürlüklü bantlarına composite işlemi uygulanarak tüm bantlar tek bir görüntüde toplanmıştır. Elde edilen görüntü çalışma alanı sınırlarına göre kesilmiştir.


Birleştirilen 20 m çözünürlüklü bantlar 10 m çözünürlüklü B04 bandı kullanılarak pan-sharpening işlemi uygulanarak 10 m çözünürlüklü hale getirilmiştir (Şekil 5.6.). Pan-sharpening tekniği, yüksek mekansal çözünürlükteki pankromatik banttandır çıkarılan mekansal bilgileri kullanarak, multispektral bantların mekânsal çözünürlüğünün geliştirilmesini sağlar (Jovanovi'c ve ark., 2016 ; Rahaman ve ark., 2017).



Şekil 5.6. Pan-sharpening görüntü

5.2.2. Görüntülerin Sınıflandırılması


Pan-sharpening işleminin ardından elde edilen görüntüyü sınıflandırma işlemine geçilmiştir. Çalışmada kullanılmak amacıyla daha önceden kayısı bahçeleri ve diğer sınıflar olmak üzere iki sınıf için sırasıyla 110 ve 91 adet poligondan oluşan eğitim verisi hazırlanmıştır. Qgis yazılımıyla önceden hazırlanmış olan eğitim verisi ile Arcgis yazılımında interactive supervised classification araç çubuğu kullanılarak sınıflandırma işlemi yapılmıştır. Bu araç çubuğu herhangi bir imza dosyası oluşturmadan arazi örtüsü sınıflandırmasını gerçekleştirmemizi sağlar (Mamun ve ark., 2013). Sınıflandırılmış görüntü Şekil (5.7.)’de gösterilmiştir.



Şekil 5.7. Sınıflandırılmış görüntü

5.2.3. Sınıflandırılmış Görüntünün Filtrelenmesi

Sınıflandırma işleminin ardından elde edilen görüntüye üç kez majority filter işlemi uygulanmıştır (Şekil 5.8.). Tematik imgelerle (ve sınıflandırma haritalarının kullanımı ile) uğraşırken, tek bir büyük arazi kullanım sınıfında çok küçük arazi kullanım kümesi olduğu görülür. Bu sahte kümeleri kaldırmak ve daha gerçekçi bir arazi kullanım sınıfı haritası üretmek için, Majority Filter'i kullanıyoruz (URL-17). Majority filtresi uygulanarak küçük piksellerden oluşan alanlar filtrelenmiştir.




Şekil 5.8. Filtre uygulanmış görüntü

5.2.4. Doğruluk Analizi

Filtreleme işleminin ardından hata matrisi yöntemi kullanılarak sınıflandırma işleminin doğruluk analizi gerçekleştirilmiştir. Çalışmada kullanılmak amacıyla daha önceden kayısı ve diğer olmak üzere iki sınıf için sırasıyla 113 ve 88 adet poligon oluşturulan test verisi hazırlanmıştır. Qgis ortamında hazırlanan test verileri düzenlenerek Matlab yazılımında confusion matrix kodu çalıştırılarak analiz gerçekleştirilmiştir (Şekil 5.9.). Şekilde, yeşil renkli köşegen hücreler doğru sınıflandırmanın sayısını ve yüzdesini göstermektedir. Örneğin, 86 örnek, tüm örneklerin% 42,8'ine karşılık gelen “diğer” sınıfına ait veri olarak doğru şekilde sınıflandırılmıştır. Köşegen olmayan hücreler, hataların nereden geldiğini gösterir. Örneğin, ilk satırda, “diğer” örneklerinin 2'si yanlış bir şekilde tüm örneklerin% 1,0 'ına karşılık gelen “diğer” olarak sınıflandırılmıştır ve “diğer” örneklerinin 5'i ,% 2,5 olarak “kayısı” olarak yanlış sınıflandırılmıştır. En sağdaki sütun, tahmin edilen her bir sınıfın doğruluğunu gösterirken, en alttaki satır her bir gerçek sınıfın doğruluğunu gösterir. Örneğin, 88 (86 + 2) “diğer” tahmininden % 97,7'si doğru ve % 2,3'ü yanlış ; 91 (86 + 5) “diğer” örneğinin % 94,5'i doğru şekilde “diğer” olarak tahmin edilmiştir ve % 5,5'i “kayısı”

olarak yanlış tahmin edilmiştir. Sağ alttaki hücre, % 96.5 olan sınıflandırma genel doğruluğunu gösterir (Zhang ve ark., 2019).



Şekil 5.9. Doğruluk analizi sonuçları

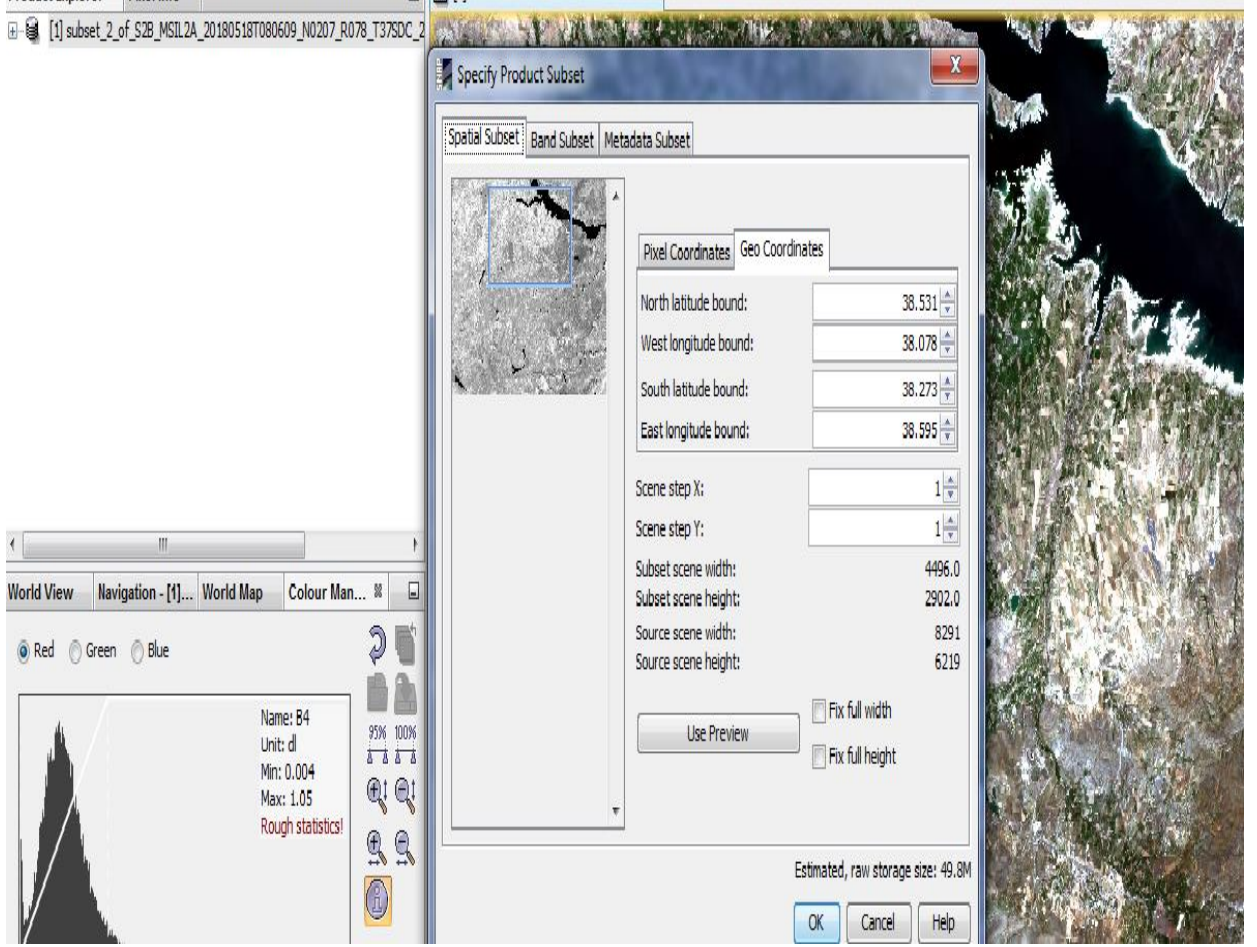
5.2.4. NDVI Görüntülerinin Oluşturulması

Çalışmada rekolte tahmini amacıyla gerçekleştirilen analizde 2018 ve 2019 yıllarına ait Mayıs, Temmuz ve Eylül aylarının görüntüleri kullanılmıştır (Tablo 5.1.).

Tablo 5.1. Kullanılan uydu görüntüleri

2018	2019
18 Mayıs	13 Mayıs
17 Temmuz	22 Temmuz
15 Eylül	20 Eylül

Çalışmada kullanılan uydu görüntülerinin ön işlemleri Snap yazılımıyla gerçekleştirilmiştir. İlk olarak uydu görüntülerine 10 m çözünürlüklü B04 bandına göre resample işlemi uygulanmıştır. Bu işlem sayesinde görüntünün bantları aynı çözünürlüğe getirilmiştir. Bu işlemin ardından uydu görüntüsü sınırları çalışma alanını kapsayacak şekilde subset işlemi uygulanmıştır (Şekil 5.10.).



Şekil 5.10. 2018 Mayıs ayı görüntüsü subset işlemi

Ardından uydu görüntüsünün kırmızı (B4) bandı ve kızılötesi (B8A) bandı kullanılarak (NDVI) Normalleştirilmiş Fark Bitki Örtüsü İndeksi (Zhang ve ark., 2017) hesaplanmıştır. Çalışmada kullanılan NDVI görüntüleri, Şekil 5.11’de gösterilen model kullanılarak oluşturulmuştur. Bu işlemler tüm görüntüler için ayrı ayrı uygulanmıştır (Şekil 5.12., Şekil 5.13., Şekil 5.14., Şekil 5.15., Şekil 5.16., Şekil 5.17.).

The screenshot displays the SNAP (Scientific Data Processing) software interface. The main window is titled "Graph Builder" and shows a workflow graph with three steps: "Read", "BandMaths", and "Write", connected by red arrows. The "BandMaths" step is currently selected.


An "Arithmetic Expression Editor" dialog box is open over the "BandMaths" step. It contains the following information:

- Data sources:** B2, B3, B4, B5, B6, B7, B8, B8A
- Expression:** $(B8A - B4) / (B8A + B4)$
- Target Band:** ndvi
- Target Band Type:** float32
- Band Unit:** (empty)
- No-Data Value:** 0.0
- Expression:** (empty)


Below the dialog box, a status message reads "Expression is invalid." The "Arithmetic Expression Editor" also includes checkboxes for "Show bands", "Show masks", "Show tie-point grids", and "Show single flags", along with buttons for "OK", "Cancel", and "Help".

In the background, the "Product Explorer" shows a file named "[1] subset_of_S2A_MSL2A_20170521T081611_N0205_R121...". The "World View" shows a satellite image of a landscape with a river. The "Pixel Info" panel shows statistics for band B4: Name: B4, Unit: dl, Min: 1E-4, Max: 1.27, and "Rough statistics!".


Şekil 5.11. NDVI Model




Şekil 5.12. 2018 yılı Mayıs ayı NDVI haritası




Şekil 5.13. 2018 yılı Temmuz ayı NDVI haritası




Şekil 5.14. 2018 yılı Eylül ayı NDVI haritası



Şekil 5.15. 2019 yılı Mayıs ayı NDVI haritası




Şekil 5.16. 2019 yılı Temmuz ayı NDVI haritası




Şekil 5.17. 2019 yılı Eylül ayı NDVI haritası

5.2.5. Görüntülere Belli Aralıklarla Nokta Atılması

NDVI görüntülerinin oluşturulmasının ardından bu görüntülere nokta atılma işlemine geçilmiştir. Qgis yazılımında grid oluştur işlemi ile tüm NDVI görüntülerine 400 m aralıklarla nokta atılmıştır. Bu noktalardan, önceden sınıflandırma işlemiyle belirlenmiş olan Battalgazi ve Yeşilyurt ilçelerindeki kayısı bahçelerine denk gelen noktalar, Battalgazi ve Yeşilyurt ilçeleri için ayrı ayrı kesilmiştir (Şekil 5.18., Şekil 5.19.).




Şekil 5.18. Battalgazi ilçesi kayısı nokta




Şekil 5.19. Yeşilyurt ilçesi kayısı nokta

5.2.6. Noktaların NDVI Değerlerinin Okutulması

Noktalar belirlendikten sonra bu noktaların NDVI değerlerinin okutulması işlemine geçilmiştir. Bu noktaların NDVI görüntülerine ait sayısal değerlerin hesaplanması işlemi için qgis yazılımı kullanılmıştır. Qgis yazılımı point sampling tool kullanılarak bu noktaların NDVI değerleri Battalgazi ve Yeşilyurt ilçeleri tüm görüntüleri için ayrı ayrı hesaplanmıştır (Şekil 5.20., Şekil 5.21.).



Şekil 5.20. Battalgazi ilçesi nokta ndvi hesaplama



Şekil 5.21. Yeşilyurt ilçesi nokta ndvi hesaplama

6. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

6.1. NDVI Değerleri İstatistiksel Hesaplamalar

Çalışmada rekolte tahmin verileriyle olan korelasyonu değerlendirmek amacıyla kullanılacak noktaların NDVI görüntülerine ait sayısal değerlerin hesaplanması işlemi 2018 ve 2019 yıllarına ait tüm görüntüler için Battalgazi ve Yeşilyurt ilçeleri için ayrı ayrı gerçekleştirilmiştir. Hesaplanan bu değerler Microsoft Excel ortamına aktarılarak bazı istatistiksel hesaplamalar yapılmıştır. İlk olarak hesaplama sonucu elde edilen bu değerlere filtre uygulanarak negatif NDVI değerlerinin işleme olumsuz etkide bulunmaması amacıyla 0.1 den büyük değerler seçilmiştir. Ardından ayrı ayrı her tarihteki görüntünün her iki ilçe için elde edilen NDVI değerlerinin ortalamaları alınmıştır. Bu ortalamalar Tablo 6.1’ de gösterilmiştir. Örneğin, Battalgazi ilçesi 2018 yılı Mayıs ayı noktalarının NDVI değerleri ortalaması 0.484726 olurken Yeşilyurt ilçesi 2018 yılı Mayıs ayı noktalarının NDVI değerleri ortalaması 0.426029 olarak bulunmuştur.

Tablo 6.1. Kullanılan ndvi değerleri ortalamaları

	18-05-B	18-07-B	18-09-B	18-05-Y	18-07-Y	18-09-Y
ortalama	0.484726	0.432258	0.441449	0.426029	0.36968	0.365371
	19-05-B	19-07-B	19-09-B	19-05-Y	19-07-Y	19-09-Y
ortalama	0.529875	0.430374	0.444952	0.468804	0.364456	0.369186

6.2. NDVI - Rekolte İlişkisi

Ortalamalar hesaplandıktan sonra aylara göre NDVI ortalama değerleri incelenmiştir (Tablo 6.2.). Tabloyu incelediğimizde: Örneğin, 2018 yılı Battalgazi ilçesi Mayıs ayı NDVI değerleri ortalaması 0.484726, Temmuz ayı ortalaması 0.432258 ve Eylül ayı ortalaması 0.441449 olarak bulunurken 2019 yılı Battalgazi ilçesi Mayıs ayı NDVI değerleri ortalaması 0.529875, Temmuz ayı ortalaması 0.430374 ve Eylül ayı ortalaması 0.444952 olarak bulunmuştur. Sonuçlar değerlendirildiğinde her iki ilçe içinde Mayıs ayı NDVI değerlerinin diğer aylara göre daha yüksek olduğu görülmüştür.

Tablo 6.2. Aylara göre ndvi ve rekolte analizi sonuçları

MAYIS				
	18-05-B	19-05-B	18-05-Y	19-05-Y
NDVI	0.484726	0.529875	0.426029	0.468804
Rekolte	60	66	55	55
Rekolte/NDVI	123.7812	124.5577	129.0991	117.3199
TEMMUZ				
	18-07-B	19-07-B	18-07-Y	19-07-Y
NDVI	0.432258	0.430374	0.36968	0.364456
Rekolte	60	66	55	55
Rekolte/NDVI	138.8061	153.3549	148.7775	150.91
EYLÜL				
	18-09-B	19-09-B	18-09-Y	19-09-Y
NDVI	0.441449	0.444952	0.365371	0.369186
Rekolte	60	66	55	55
Rekolte/NDVI	135.9161	148.3307	150.5318	148.9763

Aylara göre NDVI ortalama değerleri incelendikten sonra yıllara göre NDVI ortalama değerleri ve Malatya Ticaret ve Sanayi Odası rekolte tahmin verileri kullanılarak rekolte ve NDVI ilişkisi irdelenmiştir.

Aylara göre değerlendirme yaptığımızda Mayıs ayı NDVI ortalama değerlerinin diğer aylara göre daha yüksek olduğu görülmüştür. Aynı şekilde yıllara göre değerlendirme yaptığımızda da Mayıs ayı NDVI değerleri diğer aylara göre daha yüksektir. Fakat yıllara göre değerlendirdiğimizde 2019 yılı NDVI değerleri her iki ilçe içinde 2018 yılına göre daha yüksek olduğu tespit edilmiştir. Aynı şekilde 2019 yılı Battalgazi ilçesi Malatya Ticaret ve Sanayi Odası rekolte tahmin verilerinde ağaç başına ortalama verim 66 kg olarak belirlenirken 2018 yılında 60 kg olarak belirlenmiştir. Buna göre 2018 yılı NDVI değerleri 2019 yılında artarken aynı şekilde rekolte tahmin değerleri de 2019 yılında artmıştır. Bu durum NDVI ve rekolte arasında bir korelasyon olduğunu göstermektedir. Öte yandan NDVI ve rekolte yaşanan bu durumun 2018 yılında Malatya ilinde yaşanan don olaylarından kaynaklandığı görülmektedir. Bu sonuçlar bize rekolte tahmini için sadece NDVI verisinin yeterli olmadığını ayrıca iklimden kaynaklı don olayları gibi doğal etmenlerinde rekolte değişikliklere neden olabileceğini göstermiştir.

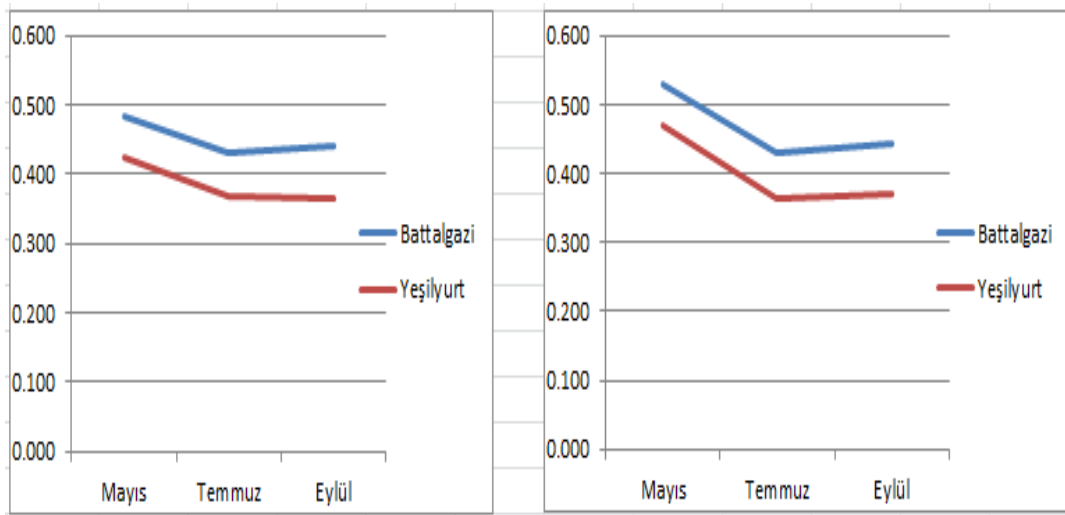
6.3. NDVI Oranları - Rekolte Oranları İlişkisi

NDVI ortalama değerleri ve rekolte tahmin verileri arasındaki ilişki incelendikten sonra yıllara göre NDVI ilçe oranları ve rekolte oranları arasındaki ilişki irdelenmiş (Tablo 6.3.) ve grafikler oluşturulmuştur (Şekil 6.1.).

Tablo 6.3. Yıllara göre NDVI ve rekolte analizi sonuçları

2018					2019				
İlçe	Mayıs	Temmuz	Eylül	Ort.	İlçe	Mayıs	Temmuz	Eylül	Ort.
Battalgazi	0.484726	0.432258	0.441449	0.452811	Battalgazi	0.529875	0.430374	0.444952	0.4684
Yeşilyurt	0.426029	0.36968	0.365371	0.387027	Yeşilyurt	0.468804	0.364456	0.369186	0.400815
Oran B/Y	1.137777	1.169276	1.208219	1.169973	Oran B/Y	1.130271	1.180869	1.205223	1.168619
Rekolte Oranı	1.090909				Rekolte Oranı	1.2			

Tabloyu incelediğimizde, 2018 yılı Mayıs ayı NDVI Battalgazi ve NDVI Yeşilyurt oranı 1.137777 iken 2019 yılı Mayıs ayı NDVI Battalgazi ve NDVI Yeşilyurt oranı 1.130271'dir. 2018 yılı Mayıs ayı NDVI oranları ile 2019 yılı Mayıs ayı NDVI oranları birbirine çok yakın değerlerdedir. Benzer şekilde 2018 yılı Battalgazi ve Yeşilyurt rekolte tahmin oranları birbirine yakın değerlerdedir. Bu durum NDVI oranlamaları ile rekolte oranlamaları arasında çok yüksek bir korelasyon olduğunu göstermektedir.



Şekil 6.1. Yıllara göre aylık NDVI değişim grafiği

Çalışma sonuçları değerlendirildiğinde rekolte tahmini ve NDVI değerleri arasında bir korelasyon bulunduğu görülmüştür. Yıllara göre değerlendirdiğimizde

Mayıs ayı NDVI oranları iki yılda da birbirine çok yakındır ve her iki yılın rekolte tahmini oranları da birbirine yakın değerlerdedir. 2019 yılında rekolte tahmini oranı biraz daha artmışken Mayıs ayı NDVI oranı da 2018 yılına göre biraz daha artmıştır. Bu durum kayısı rekolte tahmini uygulamalarında Mayıs ayı NDVI verisinden yararlanılabileceğini göstermektedir.

7. SONUÇLAR VE ÖNERİLER

Hızlı nüfus artışı, iklim değişikliği gibi etmenlerden dolayı dünyada giderek artan bir gıda talebi söz konusudur. Bu bağlamda tarım alanlarının izlenmesi, yönetimi ve ülke tarım politikalarının belirlenmesinde ; mahsul tipi haritaları, mahsul alanı ve mahsul verimi tahminleri önemli bir rol oynamaktadır. Bu bağlamda uzaktan algılama, uygun maliyetli bir şekilde büyük ölçekte bilgi üretme kabiliyetinden dolayı mahsul haritalamada önemli bir araçtır.

Bu çalışmada 2018 ve 2019 yıllarına ait üç farklı tarihte alınan Sentinel-2A uydu görüntülerinden elde edilen NDVI verileri kullanılarak Malatya ilinin Battalgazi ve Yeşilyurt ilçeleri kayısı bahçeleri NDVI oranları ile Malatya Ticaret ve Sanayi Odası Battalgazi ve Yeşilyurt ilçeleri için yapılan rekolte tahmin oranları arasında bir korelasyon olup olmadığı irdelenmiştir. Öncelikle 2018 Eylül ayına ait uydu görüntüsüne kontrollü sınıflandırma işlemi uygulanarak doğruluk analizi gerçekleştirilmiştir. Kayısı bahçeleri % 96.5 doğrulukla tespit edilmiştir. Sonrasında Battalgazi ve Yeşilyurt ilçeleri kayısı bahçelerine 400m aralıklarla noktalar atılmıştır. 2018 ve 2019 yılları Mayıs, Temmuz ve Eylül aylarına ait görüntüler kullanılarak bu noktaların her iki ilçe için ayrı ayrı NDVI değerleri hesaplanmıştır. Ardından NDVI değerleri ortalamaları alınarak Battalgazi/Yeşilyurt oranları her görüntü için ayrı ayrı hesaplanmıştır. Bu veriler Malatya Ticaret ve Sanayi Odası Battalgazi/Yeşilyurt rekolte tahmin verileriyle kıyaslandığında Mayıs ayı NDVI oranları ile aralarında yüksek bir korelasyon olduğu ve kayısı için yapılacak rekolte tahmini uygulamalarında Mayıs ayı NDVI verisinden yararlanılabileceği görülmüştür.

Uygulamada karşılaşılan en büyük sorunlardan biri Sentinel-2 uydu verilerinin mekânsal çözünürlüğü bireysel ağaç tespiti için yetersiz olduğu için kayısı ağaçlarının bireysel tespiti yapılamamış olup kayısı bahçesi şeklinde alansal olarak tespit yapılmıştır. Malatya ilinde permanent crop (kalıcı mahsul), kayısı bahçeleri olduğundan tarımsal alanlar kayısı bahçeleri olarak tanımlanmıştır.

Sonuçlar bize Sentinel-2 veri bantlarının farklı ağaç türlerinin bireysel olarak tespiti için yeterli çözünürlüğe sahip olmadığını göstermiştir. Kayısı ağaçlarının doğrudan tespitini kolaylaştıracak daha yüksek çözünürlüklü uydu verileri ve nesne tabanlı sınıflandırma tekniklerinin kullanımı ile daha kapsamlı ve yüksek doğruluklu sonuçların elde edilebileceği öngörülmektedir. Ayrıca, kayısı meyvesinin doğrudan tespiti, rekolte tahmini ve uygulamalarda kolaylık sağlayarak daha doğru sonuçlar elde

etmeyi sağlayabileceği için kayısı meyvesinin tespiti ile rekolte tahmini amacıyla İnsansız Hava Araçları kullanılabilir. Fakat bu yöntemlerin de yüksek maliyet gibi bazı dezavantajları bulunmaktadır. Ayrıca İnsansız Hava Araçları kullanılarak yapılan çalışmalar çoğunlukla tek görüntü alımlarına dayanmaktadır ve büyüme mevsiminin değişken doğasını açıklamamaktadır.

Sentinel-2 optik verileri Avrupa Uzay Ajansı tarafından ücretsiz olarak sunulan, yüksek tekrar ziyaret süresine sahip olması, 10 m çözünürlüklü bant varlığı ve bitki örtüsü tespitinde kolaylık sağlayan 20 m çözünürlüklü bant varlığı gibi birçok avantajlara sahiptir. Sentinel-2 uydu verileri kullanılarak yapılan bu çalışmada NDVI değerlerinden yararlanılarak rekolteyle olan ilişkisi incelenmiştir. Çalışmada Mayıs ayı NDVI oranları ile rekolte tahmin oranları arasında bir korelasyon olduğu görülmüştür.

Çalışmada, kayısının fenolojik gelişimi göz önünde bulundurulduğunda çiçeklenme dönemi olan Mart, Nisan ayı görüntüleri iklim koşullarından (sis, bulut, kar) kaynaklı düzgün görüntü bulunamadığından rekolte tahmini amacıyla kullanılmak için incelenememiştir. Sentinel-1 SAR verileri ve Sentinel-2 verilerinin kombinasyonu bu sorunlara çözüm aranabilir.

Malatya Ticaret ve Sanayi Odası rekolte tahmin verileriyle korelasyonun irdelenmesi amacıyla farklı ilçelere ait uydu verilerinin kullanımıyla kıyaslamalar artırılarak uygulamanın genişletilmesi sağlanabilir.

8. KAYNAKLAR

- Akar, Ö., ve GÜNGÖR O., 2013, Eş dizimlilik matrisi ve rastgele orman sınıflandırıcısı ile çay ve fındık alanlarının sınıflandırılması, Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği VII. Teknik Sempozyumu (TUFUAB'2013), 23-25 Mayıs 2013, KTÜ, Trabzon.
- Anand, A., 2017, Unit 12 Image Enhancement and Transformation, 29-33, 2017
- Azar, R., Villa, P., Stroppiana, D., Crema, A., Boschetti, M., ve Brivio, P. A., 2016, Assessing in-season crop classification performance using satellite data: a test case in Northern Italy, *European Journal of Remote Sensing*, 49:1, 361-380
- Bargoti, S., and Underwood, J. P., 2017, Image Segmentation for Fruit Detection and Yield Estimation in Apple Orchards, *Journal of Field Robotics*, 34 (2017) 1039-1060
- Belgiu, M., and Csillik, O., 2018, Sentinel-2 cropland mapping using pixel-based and object-based timeweighted dynamic time warping analysis, *Remote Sensing of Environment* 204 (2018) 509–523
- Clerici, N., Calderón, C. A. V., and Posada, J. M., 2017, Fusion of Sentinel-1A and Sentinel-2A data for land cover mapping: a case study in the lower Magdalena region, Colombia, *Journal of Maps*, 13:2, 718-726
- Çelik, Y. B., 2015, Mısır Ve Pamuk Ekili Alanların Çok Zamanlı Uydu Görüntüleri Ve Obje Tabanlı Sınıflandırma Yöntemi İle Tespiti, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, 2015, 18
- Delen, A., ve Balık Şanlı, F., 2017, Pamuk ekili alanların nesne tabanlı sınıflandırma yöntemi ile belirlenmesi: menemen örneği, *Journal of New Results in Engineering and Natural Science*, Number:6, Year:2017, 1-8.
- Dente, L., Satalino, G., Mattia, F., and Rinaldi, M., 2008, Assimilation of leaf area index derived from ASAR and MERIS data into CERES-Wheat model to map wheat yield, *Remote Sensing of Environment* 112 (2008) 1395–1407
- Duraisamy, V., 2019, Sen2-agri-crop type mapping pilot study using sentinel-2 satellite imagery in India, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Volume XLII-3/W6, 2019, ISPRS-GEOGLAM-ISRS Joint Int. Workshop on “Earth Observations for Agricultural Monitoring”, 18–20 February 2019, New Delhi, India
- Esetlili, M. T., Özen F., Kandemir, B. N., Kurucu, Y., ve Bolca, M., 2015, Uzaktan Algılama Tekniği ile Pamuk Tarla Verimi Tahmin Doğruluğunun Arttırılmasında Kırmızı Kenar (Rededge) Band Kullanımının Katkısı, *Ege Üniv. Ziraat Fak. Derg.*, 2015, 52 (2):161-168
- Gupta, S., 2018, *Active and Passive Remote Sensing*, 3-4, 2018

- Hassani, D., Dastjerdi, R., Soleimani, A., Jaffaraghaei, M., Rezaee, R., Vahdati, K., Deghani, A., Hadadnejh, H., Asefnokhostin, M., Mozaffari, M., and Eskandari, S., 2014, A Model for Estimation of the Potential Yield of Walnut Trees, VIIth International Walnut Symposium , 2014
- Heupel, K., Spengler, D., and Itzerott, S., 2018, A Progressive Crop-Type Classification Using Multitemporal Remote Sensing Data and Phenological Information, *Journal of Photogrammetry, Remote Sensing and Geoinformation Science* (2018) 86:53–69
- Immitzer, M., Vuolo, F., and Atzberger, C., 2016, First Experience with Sentinel-2 Data for Crop and Tree Species Classifications in Central Europe, *Journal of Remote Sensing*, 2016, 8, 166
- Inglada, J., Vincent, A., Arias, M., and Marais-Sicre, C., 2016, Improved Early Crop Type Identification By Joint Use of High Temporal Resolution SAR And Optical Image Time Series, *Journal of Remote Sensing*, 2016, 8, 362
- Kaplan, G., and Avdan, U., 2018a, Sentinel-2 Pan Sharpening—Comparative Analysis, *Journal of Proceedings* 2018, 2, 345
- Kaplan, G., and Avdan, U., 2018b, Sentinel-1 and Sentinel-2 data fusion for wetlands mapping: Balıkdamı, Turkey. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Volume XLII-3, 2018 , ISPRS TC III Mid-term Symposium “Developments, Technologies and Applications in Remote Sensing”, 7–10 May, Beijing, China
- Kerle, N., Lucas, L. F., Janssen and Gerrit C., Huurneman (eds.), 2004, (ITC Educational Textbook Series; 2), Third edition; In print: ISBN 90–6164–227–2 ITC, Enschede, The Netherlands, ISSN 1567–5777 ITC Educational Textbook Series, 2004
- Lussem, U., Hütt, C., and Waldhoff, G., 2016, Combined analysis of sentinel-1 and rapideye data for improved crop type classification: an early season approach for rapeseed and cereals, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Volume XLI-B8, 2016, XXIII ISPRS Congress, 12–19 July 2016, Prague, Czech Republic
- Malik, Z., Ziauddin, S., Shahid, A. R., and Safi, A., 2016, Detection and Counting of On-Tree Citrus Fruit for Crop Yield Estimation, (IJACSA) *International Journal of Advanced Computer Science and Applications*, Vol. 7, No. 5, 2016
- Mamun, A. A., Mahmood, A., Rahman, M., 2013, Identification and Monitoring the Change of Land Use Pattern Using Remote Sensing and GIS: A Case Study of Dhaka City, *IOSR Journal of Mechanical and Civil Engineering (IOSR-JMCE)* e-ISSN: 2278-1684, p-ISSN: 2320-334X, Volume 6, Issue 2 (Mar. - Apr. 2013), PP 24
- Morindo, M., Maselli, F., Bindi, M., 2007, A simple model of regional wheat yield based on NDVI data, *European Journal of Agronomy* · April 2007

- Nagraj, M. G., and Karegowda, A. G., 2016, Crop Mapping using SAR Imagery: An Review, *International Journal of Advanced Research in Computer Science*, 7 (7), Nov–Dec, 2016,47-52
- Nitze, I., Schulthess, U., and Asche, H., 2012, Comparison of machine learning algorithms random forest, artificial neural network and support vector machine to maximum likelihood for supervised crop type classification, *Proceedings of the 4th GEOBIA*, May 7-9, 2012 - Rio de Janeiro - Brazil. p.035
- Rahaman, K. R., Hassan, Q. K., and Ahmed, M. R., 2017, Pan-Sharpening of Landsat-8 Images and Its Application in Calculating Vegetation Greenness and Canopy Water Contents, *ISPRS Int. J. Geo-Inf.* 2017, 6, 168
- Rembold, F., Atzberger, C., Savin, I., and Rojas, O., Using low resolution satellite imagery for yield prediction and yield anomaly detection, *Journal of Remote Sensing* 2013, 5, 1704-1733
- Robson, A. J., Rahman, M. M., Muir, J., Saint, A., Simpson, C., and Searle, C., 2016, Evaluating satellite remote sensing as a method for measuring yield variability in Avocado and Macadamia tree crops, 19th Precision Agriculture Symposium in Australasia, September, 2016
- Saini, R., and Ghosh, S. K., 2018, Crop classification on single date sentinel-2 imagery using random forest and support vector machine, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Volume XLII-5, 2018, ISPRS TC V Mid-term Symposium “Geospatial Technology – Pixel to People”, 20–23 November 2018, Dehradun, India
- Siachalou, S., Mallinis, G., and Tsariki-Strati, M., 2015, A Hidden Markov Models Approach for Crop Classification: Linking Crop Phenology to Time Series of Multi-Sensor Remote Sensing Data, *Journal of Remote Sensing*, 2015, 7, 3633-3650
- Szostak, M., Hawryło, P., and Piela, D., 2018, Using of Sentinel-2 images for automation of the forest succession detection, *European Journal of Remote Sensing*, 51:1, 142-149
- Tubau Comas, A., Valente, J., Kooistra, L., 2019, Automatic apple tree blossom estimation from uav rgb imagery, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Volume XLII-2/W13, 2019, ISPRS Geospatial Week 2019, 10–14 June 2019, Enschede, The Netherlands
- Turvey, C.G., McLaurin, M.K., 2012, Applicability of the Normalized Difference Vegetation Index (NDVI) in Index-Based Crop Insurance Design, *Journal of Weather, Climate and Society*, Volume 4, October 2012
- Uça Avcı, Z. D., ve Sunar F., 2010, Çok-zamanlı optik veri setinin tarımsal haritalama amaçlı nesne-tabanlı sınıflandırılması: türkgeldi örneği, III. Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu, 11 – 13 Ekim 2010, Gebze – Kocaeli

- Uça Avcı, Z. D., ve Sunar F., 2014, Çeltik tarlalarının haritalanmasında çok-zamanlı radar uydu verilerinin kullanımı: meriç (İpsala-enez) havzası örneği, V. Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu , 14-17 Ekim 2014, İstanbul
- Ustuner, M., Sanli, F.B., Abdikan, S., Esetlili, M. T., and Kurucu, Y., 2014, Crop type classification using vegetation indices of rapideye imagery, The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume XL-7, 2014, ISPRS Technical Commission VII Symposium, 29 September – 2 October 2014, Istanbul, Turkey
- Vaipoulos, A.D., and Karantzalos, K., 2016, Pansharpening on the narrow VNIR and SWIR spectral bands of Sentinel-2, The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume XLI-B7, 2016, XXIII ISPRS Congress, 12–19 July 2016, Prague, Czech Republic
- Van Beek, J., Tits, L., Somers, B., Deckers, T., Verjans, W., Bylemans, D., Janssens, P., and Coppin, P., 2015, Temporal Dependency of Yield and Quality Estimation through Spectral Vegetation Indices in Pear Orchards, *Journals of Remote Sensing* 2015, 7, 9886-9903
- Wall, L., Larocque, D., Leger, P.M., 2008, The early explanatory power of NDVI in crop yield modelling, *International Journal of Remote Sensing* 29(8):2211-2225, April 2008
- Wang, Q., Nuske, S., Bergerman, M., Singh, S., 2012, Automated Crop Yield Estimation for Apple Orchards, The 13th International Symposium on Experimental Robotics, 2012
- Wang, Q., Shi, W., Li, Z., and Atkinson, P. M., 2016, Fusion of Sentinel-2 images, *Remote Sensing of Environment* 187 (2016) 241–252
- Zhang, T., Su, J., Liu, C., Chen, W.H., 2017, Band Selection in Sentinel-2 Satellite for Agriculture Applications, Proceedings of the 23rd International Conference on Automation & Computing, University of Huddersfield, Huddersfield, UK, 7-8 September 2017
- Zhang, T., Su, J., Liu, C., Chen, W.H., 2019, Potential Bands of Sentinel-2A Satellite for Classification Problems in Precision Agriculture, *International Journal of Automation and Computing*, vol.16, no.1, pp.16–26, 2019
- Zhang, Z., Jin, Y., Chen, B., and Brown, B., 2019, California Almond Yield Prediction at the Orchard Level With a Machine Learning Approach, *Journal of Frontiers in Plant Science*, 18 July 2019
- (URL-1): <https://arastirma.tarimorman.gov.tr> › Belgeler › 2018-Temmuz Kayısı, [Ziyaret Tarihi: 20 Haziran 2019].
- (URL-2):https://www.nrcan.gc.ca/sites//www.nrcan.gc.ca/files/earthsciences/pdf/resource/tutor/fundam/pdf/fundamentals_e.pdf, , [Ziyaret Tarihi: 20 Mart 2020].

(URL-3): <https://www.pleasantvalleypd.org/handlers/filedownload>, [Ziyaret Tarihi: 20 Mart 2020].

(URL-4): www.univie.ac.at/site/imagers.gsfc.nasa.gov/ems, [Ziyaret Tarihi: 20 Mart 2020].

(URL-5): <https://sciencing.com/7-types-electromagnetic-waves-8434704.html>, [Ziyaret Tarihi: 20 Mart 2020].

(URL-6): <https://www.lumitex.com/blog/visible-light-spectrum>, [Ziyaret Tarihi: 22 Mart 2020].

(URL-7): http://gsp.humboldt.edu/OLM/Courses/GSP_216_Online/lesson1-2/spectrum.html, [Ziyaret Tarihi: 22 Mart 2020].

(URL-8): http://civil.iisc.ernet.in/~nagesh/rs_docs/Energyf.pdf, [Ziyaret Tarihi: 23 Mart 2020].

(URL-9): <http://www.wamis.org/agm/pubs/agm8/Paper-2.pdf>, [Ziyaret Tarihi: 23 Mart 2020].

(URL-10): http://epgp.inflibnet.ac.in/epgpdata/uploads/epgp_content/S000017GE/P001788/M025424/ET/1512641278InteractionofEMRwithEarthsurface.pdf, [Ziyaret Tarihi: 25 Mart 2020].

(URL-11): https://www.lkouniv.ac.in/site/writereaddata/siteContent/202004101454176098nidhi_sriv_engg_Spectral_reflectance_curve.pdf, [Ziyaret Tarihi: 25 Mart 2020].

(URL-12): <http://www.egyankosh.ac.in/bitstream/123456789/39529/1/Unit-2.pdf>, [Ziyaret Tarihi: 25 Mart 2020].

(URL-13): <https://desktop.arcgis.com/en/arcmap/latest/manage-data/raster-and-images/fundamentals-of-panchromatic-sharpening.htm>, [Ziyaret Tarihi: 25 Mart 2020].

(URL-14): <https://www.intechopen.com/books/new-advances-in-image-fusion/investigation-of-image-fusion-for-remote-sensing-application>, [Ziyaret Tarihi: 25 Mart 2020].

(URL-15): <https://www.malatya.gov.tr/cografi-konum/>, [Ziyaret Tarihi: 25 Mart 2019].

(URL-16): <https://www.malatyatb.org.tr/malatya-ili-tahmini-kayisi-rekoltesi> [Ziyaret Tarihi: 6 Şubat 2019].

(URL-17): dst-iget.in/assets/pdf/tutorial/IGET_RS_006, [Ziyaret Tarihi: 13 Aralık 2019].

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Ümmü Gülsüm ŞENTÜRK
Uyruğu : TC
Doğum Yeri ve Tarihi : Malatya/1988
Telefon : 5318573378
Faks :
e-mail : gcamurlu44@gmail.com

EĞİTİM

Derece	Adı, İlçe, İl	Bitirme Yılı
Lise	: Malatya Atatürk Kız Lisesi(YDA),Malatya	2007
Üniversite	: Gümüşhane Üniversitesi,Gümüşhane	2013
Yüksek Lisans	: Necmettin Erbakan Üniversitesi, Konya	

YABANCI DİLLER

İngilizce

YAYINLAR

Çamurlu, G., ve Varlık, A., 2019, Uzaktan Algılama Teknikleri Kullanılarak Kayısı Bahçelerinin Tespiti ve Rekolte Tahmini; Malatya Battalgazi Örneği, Anadolu 3. Uygulamalı Bilimler Kongresi, 28-29 Aralık 2019, Diyarbakır, Türkiye