



T.C.
BATMAN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

LANDSAT 8 UYDU GÖRÜNTÜ İNDEKSLERİ KULLANILARAK
TARIMSAL ÜRÜNLERİN MAKİNE ÖĞRENME YÖNTEMLERİ
İLE TESPİT EDİLMESİ

Müslime ALTUN

YÜKSEK LİSANS

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM

Şubat-2021
BATMAN
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Müslime ALTUN tarafından hazırlanan “LANDSAT 8 UYDU GÖRÜNTÜ İNDEKSLERİ KULLANILARAK TARIMSAL ÜRÜNLERİN MAKİNE ÖĞRENME YÖNTEMLERİ İLE TESPİT EDİLMESİ” adlı tez çalışması 12/02/2021 tarihinde aşağıdaki jüri üyeleri tarafından oy birliği ile Batman Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Dr. Öğr. Üyesi Ömer TÜRK

.....

Danışman

Dr. Öğr. Üyesi Emrullah ACAR

.....

Üye

Dr. Öğr. Üyesi Abidin ÇALIŞKAN

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Şahnaz TİĞREK
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

Müslime ALTUN

Tarih: 15.02.2021

ÖZET

YÜKSEK LİSANS

LANDSAT 8 UYDU GÖRÜNTÜ İNDEKSLERİ KULLANILARAK TARIMSAL ÜRÜNLERİN MAKİNE ÖĞRENME YÖNTEMLERİ İLE TESPİT EDİLMESİ

Müslime ALTUN

Batman Üniversitesi Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Emrullah ACAR

2021, 74 Sayfa

Jüri

Dr. Öğr. Üyesi Emrullah ACAR

Dr. Öğr. Üyesi Ömer TÜRK

Dr. Öğr. Üyesi Abidin ÇALIŞKAN

Gelişen uydu görüntü teknolojilerinden elde edilen spektral özellikler makine öğrenme teknikleri ile birlikte kullanıldığında, küçük bir alan üzerindeki verilerle eğitilen sistem sayesinde büyük bir alan üzerindeki tarımsal ürünlerin kısa zamanda yüksek doğruluk oranı ile tespiti mümkündür. Bu çalışmada, uydu görüntü indeksleri ve farklı makine öğrenme teknikleri kullanılarak tarımsal ürünlerin tespiti amaçlanmıştır.

İlk aşamada, tespiti yapılacak nesnenin üzerinde bulunduğu alana ait Landsat-8 uydu görüntüleri temin edilmiş ve nesne olarak tarımsal ürünler kullanılmıştır. Tarım ürünleri içerisindeki gelişme ve hasat zamanları göz önünde bulundurularak buğday ve mercimek ürünlerinin yoğunlukta olduğu bir tarım arazisi seçilmiştir. Görüntülerdeki yansıma indekslerinin hesaplanması için tarımsal ürünlerin gelişim ve hasat zamanına yakın olduğu bir zaman dilimi seçilmiş; 2018 yılının Mayıs ve Ağustos aylarına karşılık gelen Landsat-8 uydu görüntüleri kullanılmıştır. Daha sonra, pilot tarım alanı içerisinde belirlenen örnek noktalara karşılık gelen koordinatlar, Landsat-8 uydu görüntüleri üzerine aktarılmış ve uydu görüntülerinin 4. ve 5. bantlarına denk gelen yansıma indeksleri yardımıyla, bu noktalar için NDVI değerleri hesaplanmıştır.

Son aşamada, elde edilen NDVI indeks değerleri farklı makine öğrenme tekniklerinin (K En Yakın Komşu, Destek Vektör Makineleri ve Naive Bayes) girişlerinde kullanılarak tarımsal ürünler (Mercimek ve Buğday) tespit edilmiştir. Sonuç olarak, en iyi performansa %86,4 ortalama doğruluk ile Naive Bayes yöntemiyle ulaşılmıştır. Ayrıca, gelişim dönemine ait uydu görüntüsünden elde edilen NDVI değerlerinin tespit aşamasında daha yüksek performans gösterdiği gözlemlenmiştir.

Anahtar Kelimeler: Landsat-8, Makine Öğrenmesi, Buğday, Mercimek, NDVI, Uzaktan Algılama

ABSTRACT

MS THESIS

IDENTIFICATION OF AGRICULTURAL CROPS USING LANDSAT 8 SATELLITE IMAGE INDICES BY MACHINE LEARNING TECHNIQUES

Müslime ALTUN

**DEPARTMENT OF ELECTRICAL AND ELECTRONICS ENGINEERING
INSTITUTE OF NATURAL AND APPLIED SCIENCES
UNIVERSITY OF BATMAN
THE DEGREE OF MASTER OF SCIENCE
IN ELECTRICAL AND ELECTRONICS ENGINEERING**

Advisor: Asst. Prof. Dr. Emrullah ACAR

2021, 74 Pages

Jury

Asst. Prof. Dr. Emrullah ACAR

Asst. Prof. Dr. Ömer TÜRK

Asst. Prof. Dr. Abidin ÇALIŞKAN

When spectral features obtained from developing satellite-imaging technologies are used together with machine learning techniques, it is possible to detect agricultural crops on a large area with high accuracy in a short time thanks to the system trained with data on a small area. In this study, it is aimed to determine agricultural products by using satellite image indexes and different machine learning techniques.

In the first stage, Landsat-8 satellite images of the area where the object to be detected is located were obtained and agricultural products were used as objects. Considering the development and harvest times of agricultural products, an agricultural land where wheat and lentil products are concentrated was selected. In order to compute the reflection indexes in the images, a time period in which agricultural products are close to the development and harvest time was preferred; Landsat-8 satellite images corresponding to May and August 2018 were used. Then, the coordinates corresponding to the sample points determined in the pilot agricultural area were imported to the Landsat-8 satellite images and NDVI values for these points were calculated with the help of the reflection indexes corresponding to the 4th and 5th bands of the satellite images.

In the last stage, agricultural crops (Lentil and Wheat) were determined by using the obtained NDVI index values as the inputs of different machine learning techniques (K Nearest Neighbor, Support Vector Machines and Naive Bayes). As a result, the best performance was achieved with the Naive Bayes method with an average accuracy of 86.4%. In addition, it was observed that NDVI values obtained from the satellite image of the development period showed higher performance in the detection phase.

Keywords: Landsat-8, Machine Learning, Wheat, Lentil, NDVI, Remote Sensing.

ÖNSÖZ

Bu çalışma; Batman Tarım Müdürlüğü Hibe Destek kapsamında kontrol edilen tarım arazisi alanları kullanılmıştır. Desteklerinden ötürü Harita Birimine teşekkür ederim.

Bu tez çalışması süresince her anlamda yardımını, bilimsel katkılarını ve tecrübelerini hiçbir zaman esirgemeyen değerli danışman hocam Dr. Öğr. Üyesi Emrullah ACAR'a, çalışmalarım boyunca her konuda destek veren kıymetli Cengiz ASLAN ve Abdurrahman GÖNENÇ'e teşekkür ederim.

Tezin hazırlanması sırasında her konuda fedakârlığını gösteren, maddi ve manevi yardımlarını esirgemeyen aileme, Ayşe EKMEN, Büşra BELTEKİN ve Öğr. Görevlisi Demet ERDAĞ'a sonsuz şükranlarımı sunarım.

Müslime ALTUN
BATMAN-2021

İÇİNDEKİLER

	Sayfa
TEZ BİLDİRİMİ.....	iii
ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
ÇİZELGE LİSTESİ	ix
ŞEKİL LİSTESİ.....	xi
KISALTMA VE SİMGELER.....	xii
1. GİRİŞ.....	1
2. KAYNAK ARAŞTIRMALARI.....	3
2.1. I. Gruba Ait Literatür Çalışmaları	3
2.2. II. Gruba Ait Literatür Çalışmaları	5
3. MATERYAL VE YÖNTEM	11
3.1. Çalışma Alanı	12
3.2. Veri Toplama... ..	13
3.2.1. Landsat	13
3.2.1.1. Landsat-8 Uydusu	15
3.2.1.2. Operasyonel Arazi Görüntüleyici (OLI)	16
3.2.1.3. Termal Kızılötesi Algılayıcı (TIRS)	17
3.3. Ön İşlem	17
3.3.1 Landsat-8 Görüntüsü Ön İşlemleri... ..	18
3.4. Özellik Çıkarımı.....	23
3.4.1 Normalize Edilmiş Fark Bitki Örtüsü İndeksi (NDVI) ...	23
3.5. GPS Verilerinin NDVI Görüntüsüne İşlenmesi.	25
3.6. Makine Öğrenme Teknikleri	26
3.6.1. Destek Vektör Makineleri (DVM)	27
3.6.1.1. Doğrusal Destek Vektör Makinesi Sınıflandırıcıları.....	27

3.6.1.2. Doğrusal Olarak Ayrılmama Durumu	29
3.6.2.K-En Yakın Komşu (K-NN) Algoritması	31
3.6.3.Naive Bayes (NB) Yöntemi	31
4. ARAŞTIRMA BULGULARI VE TARTIŞMA	33
4.1. NDVI Görüntüsü Elde Edilmesi	36
4.2. Makine Öğrenme Teknikleri Yardımıyla NDVI Değerlerinden Ürün Tespitine ait Bulgular	41
4.2.1.NDVI ve Destek Vektör Makineleri (DVM) Yaklaşımından Hesaplanan Performans Metrikleri	42
4.2.2.NDVI ve Naive Bayes (NB) Yaklaşımından Hesaplanan Performans Metrikleri	46
4.2.3.NDVI ve k-NN Yaklaşımından Hesaplanan Performans Metrikleri	49
4.3. Bulguların Değerlendirilmesi	53
5. SONUÇ VE ÖNERİLER.....	55
5.1. Sonuçlar	55
5.2. Öneriler	56
KAYNAKLAR.....	57
ÖZGEÇMİŞ.....	60

ÇİZELGE LİSTESİ

<u>Çizelge No</u>		<u>Savfa</u>
Çizelge 3.1.	Landsat Programında Bulunan Uyduların Görev Başlangıç-Bitiş Tarihleri ve Algılayıcı Tipleri	15
Çizelge 3.1.	Landsat Programında Bulunan Uyduların Görev Başlangıç-Bitiş Tarihleri ve Algılayıcı Tipleri	14
Çizelge 3.2.	OLI (Operational Land Imager) Spektral Bant Özellikleri	16
Çizelge 3.3.	TIRS (Thermal InfraRed Sensor) Spektral Bant Özellikleri	17
Çizelge 4.1.	NDVI Değer Tablosu ve Ürün Bilgisi	33
Çizelge 4.2.	Karışıklık Matrisi Tablosu	41
Çizelge 4.3.	06.05.2018 tarihli NDVI parametreleri ve DVM yaklaşıma ait Karışıklık Matrisi Tablosu	43
Çizelge 4.4.	06.05.2018 tarihli NDVI parametreleri ve DVM yaklaşıma ait Performans Metrikleri	43
Çizelge 4.5.	30.08.2018 tarihli NDVI parametreleri ve DVM yaklaşıma ait Karışıklık Matrisi Tablosu	44
Çizelge 4.6.	30.08.2018 tarihli NDVI parametreleri ve DVM yaklaşıma ait Performans Metrikleri	44
Çizelge 4.7.	06.05.2018 ile 30.08.2018 NDVI parametreleri ve DVM yaklaşıma Karışıklık Matrisi Tablosu	45
Çizelge 4.8.	06.05.2018 ile 30.08.2018 NDVI parametreleri ve DVM yaklaşıma ait Performans Metrikleri	45
Çizelge 4.9.	06.05.2018 tarihli NDVI parametreleri ve NB yaklaşıma ait Karışıklık Matrisi Tablosu	46
Çizelge 4.10.	06.05.2018 tarihli NDVI parametreleri ve NB yaklaşıma ait Performans Metrikleri	47
Çizelge 4.11.	30.08.2018 tarihli NDVI parametreleri ve NB yaklaşıma ait Karışıklık Matrisi Tablosu	47
Çizelge 4.12.	30.08.2018 tarihli NDVI parametreleri ve NB yaklaşıma ait Performans Metrikleri	48
Çizelge 4.13.	06.05.2018 ile 30.08.2018 NDVI parametreleri ve NB yaklaşıma Karışıklık Matrisi Tablosu	48
Çizelge 4.14.	06.05.2018 ile 30.08.2018 NDVI parametreleri ve NB yaklaşıma ait Performans Metrikleri	49
Çizelge 4.15.	06.05.2018 tarihli NDVI parametreleri ve k-NN yaklaşıma ait Karışıklık Matrisi Tablosu	50
Çizelge 4.16.	06.05.2018 tarihli NDVI parametreleri ve k-NN yaklaşıma ait Performans Metrikleri	50
Çizelge 4.17.	30.08.2018 tarihli NDVI parametreleri ve k-NN yaklaşıma ait Karışıklık Matrisi Tablosu	51

Çizelge 4.18.	30.08.2018 tarihli NDVI parametreleri ve k-NN yaklaşıma ait Performans Metrikleri	51
Çizelge 4.19.	06.05.2018 ile 30.08.2018 NDVI parametreleri ve k-NN yaklaşıma Karışıklık Matrisi Tablosu	52
Çizelge 4.20.	06.05.2018 ile 30.08.2018 NDVI parametreleri ve k-NN yaklaşıma ait Performans Metrikleri	52
Çizelge 4.21.	Makine öğrenmesi yöntemleri ile yapılan çalışmaların karşılaştırma tablosu	53
Çizelge 4.22.	Çalışmada kullanılan makine öğrenmesi tekniklerinin karşılaştırılması	54

ŞEKİL LİSTESİ

<u>Şekil No</u>		<u>Sayfa</u>
Şekil 3.1.	Seçilen noktadaki ürünü belirleme modeline ait blok diyagramı	11
Şekil 3.2.	Google Earth çalışma alanı konumu	12
Şekil 3.3.	Google Earth çalışma alanı parsellenmiş görünümü	13
Şekil 3.4.	Pilot Alana ait 06.05.2018 tarihli, Landsat-8 uydu ham görüntüsü.	19
Şekil 3.5.	06.05.2018 Tarihli Landsat-8 uydusunun 11 Bandına ait görüntüleri.	20
Şekil 3.6.	Pilot Alana ait 30.08.2018 tarihli, Landsat-8 uydu ham görüntüsü.	21
Şekil 3.7.	30.08.2018 Tarihli Landsat-8 uydusunun 11 Bandına ait görüntüleri	22
Şekil 3.8.	Yeşerme dönemi bitki örtüsü (solda) ve hasat dönemi bitki örtüsünün (sağda) görünür (visible) ve yakın kızılötesi (near infrared) ışığa karşı duyarlılığı hesaplaması (Çizim : Robert Simon)	24
Şekil 3.9.	QGIS ile seçilen 96 farklı GPS verisinin konum bilgilerine göre dağılımı	25
Şekil 3.10.	Pilot tarım alanında bulunan 96 farklı GPS verisinin konum bilgilerine göre dağılımı	26
Şekil 3.11.	Lineer olarak ayrılabilen koşul için en uygun hiperdüzlem	28
Şekil 3.12.	Lineer ayrılabilme durumunda optimal hiperdüzlem	29
Şekil 3.13.	Lineer olarak ayrılmama durumunda optimal hiperdüzlem	30
Şekil 4.1.	Landsat-8 uydusu 06.05.2018 tarihli Pilot tarım alanına ait (a) Bant 4 (görünür) ve (b) Bant 5 (yakın kızılötesi) görüntüsü	37
Şekil 4.2.	06.05.2018 tarihli Pilot tarım alanına ait NDVI görüntüsü	37
Şekil 4.3.	06.05.2018 tarihli Pilot tarım alanına ait ait tek bant yalancı renk katmanı şeklindeki Viridis bant NDVI görüntüsü	38
Şekil 4.4.	06.05.2018 tarihli Pilot tarım alanına ait ait tek bant yalancı renk katmanı şeklindeki Viridis bant NDVI görüntüsü (GPS verisi işlenmiş hali)	38
Şekil 4.5.	Landsat-8 uydusu 30.08.2018 tarihli Pilot tarım alanına ait (a) Bant 4 (görünür) ve (b) Bant 5 (yakın kızılötesi) görüntüsü	39
Şekil 4.6.	30.08.2018 tarihli Pilot tarım alanına ait NDVI görüntüsü	39
Şekil 4.7.	30.08.2018 tarihli Pilot tarım alanına ait ait tek bant yalancı renk katmanı şeklindeki RdGy bant NDVI görüntüsü	40
Şekil 4.8.	30.08.2018 tarihli Pilot tarım alanına ait ait tek bant yalancı renk katmanı şeklindeki RdGy bant NDVI görüntüsü (GPS verisi işlenmiş hali)	40

KISALTMA VE SİMGELER

CSA	: Kanada Uzay ajansı
DEM	: Dijital Yükseklik Modeli
DVM	: Destek Vektör Makine
ESA	: Avrupa Uzay Ajansı
ETM	: Geliştirilmiş Tematik Haritalandırıcı
FN	: Yanlış Negatif
FP	: Yanlış Pozitif
GIS	: Coğrafi Bilgi Sistemi
GPS	: Coğrafi Pozisyon Sistemi
HSC	: Hiperspektral Kamera
k-NN	: En Yakın Komşuluk
LDCM	: Landsat Veri Sürekliliği Misyonu
LİDAR	: Lazer Görüntüleme Algılama ve Değişme
MSC	: Multispektral Kamera
MSS	: Multispektral Tarayıcı Sistemi
MVI	: Multispektral Bitki Örtüsü İndeksi
n	: Örnek Sayısı
NASA	: Ulusal Havacılık ve Uzay Dairesi
NB	: Naive Bayer
NDVI	: Normalize Edilmiş Fark Bitki Örtüsü İndeksi
OLI	: Operasyonel Arazi Görüntüleyici
PR	: Geri Çağırma
QGIS	: Quantum Coğrafi Bilgi Sistemi
ROC	: Alıcı Çalışma Karakteristik
RVI	: Radar Bitki Örtüsü İndeksi
RVII	: Gelişmiş Radar Bitki Örtüsü İndeksi
RVIII	: Tamamen Düzeltilmiş Radar Bitki Örtüsü İndeksi
TIRS	: Termal Kızılötesi Algılayıcı
TM	: Tematik Haritalandırıcı
TN	: Doğru Negatif

TP	: Doğru Pozitif
UA	: Uzaktan Algılama
USGS	: Amerika Birleşik Devletleri Jeoloji Araştırmaları Kurumu
VH	: Dikey-Yatay
ρ_{NIR}	: Yakın Kızıl Ötesi Yansım Katsayısı
ρ_{RED}	: Görünür Işık Yansım Katsayısı
λ	: Dalga Boyu

Not: Bu tezde rakamsal ayırma işlemlerinde nokta(.) işareti kullanılmıştır.

1.GİRİŞ

Bu bölümde tezin adı, amacı içeriği kısaca anlatılmaktadır. Tezin konusu uzaktan algılama teknolojilerini kullanarak Batman Tarım Müdürlüğü'nün denetimi altında bulunan Batman Merkeze bağlı Bıçakçı Köyü pilot alanının, Landsat-8 uydularına ait görüntülerinin NDVI değerlerini kullanarak makine öğrenmesi eğitim-test tekniğiyle indekse karşılık gelen ürünün tahminini yapmaktır.

Tez çalışmasının birinci bölümünde, tespiti yapılacak ürünlerin çeşitleri ve ekili oldukları alanın belirlenmesi yapılmıştır. Seçilen pilot bölgeye ait parsellemeler dikkate alınarak alan üzerinde koordinat noktaları alınması ve koordinatlara denk gelen ürünün tespit edilmesi ve hangi dönemlere ait görüntünün kullanılacağı hakkında bilgi verilmiştir.

İkinci bölümünde, uzaktan algılama sistemlerinden kısaca bahsedilmiştir. Etrafımızı çevreleyen dünyamız beş duyumuzla algılanmaktadır. Bazı duyumlar (örneğin dokunma ve tat alma) duyu organlarımızın nesnelerle temas etmesini gerektirmektedir. Bununla birlikte, görme ve duyma duyumları yoluyla çevremizdeki bir sürü bilgiyi dış nesnelerle yakın temas gerektirmeden algılanabilmektedir. Bu anlamda, sürekli uzaktan algılama yapılmaktadır. Genellikle uzaktan algılama, uzak yerlerdeki nesneleri veya olayları kaydetme, gözlemlene ve algılama faaliyetlerini ifade eder (Weng 2013). Uzaktan algılama teknolojisinin sağladığı arazi hakkındaki en güncel bilgiler, coğrafi bilgi sistemleri teknolojisiyle birleşince alışılmış yöntemlere kıyasla hedefine daha hızlı, daha ucuz, kısıtlı insan gücüyle ulaşması nedeniyle ve kolay güncelleştirilebilir olması ile alışılmış yöntemlere büyük bir kolaylık sağlamaktadır (Kavzoğlu ve Çölkesen 2011).

Uzaktan algılama sistemleri / algılayıcıları temel olarak pasif ve aktif algılayıcılar olmak üzere iki türe ayrılabilir. Uzaktan algılama için ana enerji kaynağı güneşten gelmektedir. Uzaktan kumanda algılayıcıları, dünya yüzeyinden yansıyan veya yayılan güneş ışınımını kaydetmektedir. Enerji kaynağı bir algılayıcının dışından geldiğinde, buna pasif algılayıcı denir. Pasif algılayıcılara örnek olarak fotoğraf kameraları, elektro-optik algılayıcılar, termal IR algılayıcılar ve anten algılayıcıları verilebilir (Weng 2013).

Pasif algılayıcılar doğal olarak oluşan enerjiyi kullandıklarından, sadece gündüz saatlerinde veri yakalamaktadır. Bunun istisnası, enerji miktarı kaydedilecek kadar büyük olduğu gündüz veya gece sürecinde doğal olarak yayılan enerjiyi tespit edebilen termal IR algılayıcılarıdır (Weng 2013). Aktif algılayıcılar, algılayıcının içinden gelen enerjiyi kullanmakta ve araştırılacak hedefe yönelik kendi enerjilerini sağlamaktadır. Bu

hedeften geriye yansıyan enerji daha sonra algılayıcılar tarafından algılanmakta ve kaydedilmektedir. Aktif algılamaya örnek, bir mikrodalga sinyalinin hedefe doğru ileten ve sinyalin geri saçılmış kısmını tespit edip ölçen radardır. Başka bir örnek LiDAR'dır. Bir lazer darbesi yayar ve her hedefin yüksekliğini hesaplamak için dönüş süresini kesin olarak ölçer. Yüzeyi herhangi bir zamanda, gündüz veya gece ve herhangi bir mevsimde görüntülemek için aktif algılayıcılar kullanılabilir (Weng 2013).

Üçüncü bölümünde, Landsat- 8 uydusu ve uydunun bölgeden geçiş zamanı, tarihi, mevsimi, tarım ürünlerinin durumu dikkate alınarak uydu görüntülerinin nasıl alındığı ve kayda alınan Landsat- 8 görüntüsüne belirlenen koordinatların görüntüye aktarılması ve kullanılan bantlar hakkında bilgi verilmiştir. Landsat- 8 uydusu Şubat 2013 de yörüngeye yerleştirilen bir uydudur (USGS, 2016). Aynı noktadan 16 günde bir geçer ve gönderdiği veriler ücretsiz olarak indirilebilir. Bu çalışmada Landsat- 8 uydusu iki önemli algılayıcıya sahiptir. Bu algılayıcılar Operational Land Imager (OLI) ve Thermal Infrared Sensor (TIRS) olarak isimlendirilmiştir. Bu çalışmada Landsat- 8 uydu görüntüsüne ait 11 bant indekslerinden NDVI değerini hesaplamak için 4 (kırmızı) ve 5 (yakın kızılötesi) bantlara ait indeksler kullanılmıştır.

Dördüncü bölümde ise, Landsat- 8 uydusundan alınan görüntülerin koordinatlara karşılık gelen NDVI değerlerini makine öğrenmesine aktarılması ve makine öğrenmesi tahmini için yapılan uygulamaların detayları anlatılmıştır.

2.KAYNAK ARAŞTIRMALARI

Tarım sistemleri, Anadolu kırsalında ve dünya çapında önemli bir ekonomik sektör oluşturmaktadır. Sürdürülebilir kırsal sistemler, tarımın sağlıklı gelişimine büyük ölçüde bağlıdır. Çok yönlü bir biyofiziksel ve sosyo-ekonomik sistem olan tarım sistemi, iç talebin karşılanması için ekili ürün çeşidi oranı ve var olan potansiyelinin hesaplanması ve tarım üretim arazilerinin kullanımının planlanması birçok alanda önemli etkileri bulunmaktadır (Delen 2017) .

Bu bölümde uzaktan algılama sistemlerine ait veriler kullanılarak tarımsal araziler üzerindeki tarım alanlarına ait uydu görüntü indeksleri ile ürün tahmini için gerekli literatür taramaları yapılmış ve yapılan bu çalışmalar 2 ana grupta toplanmıştır. Bu gruplar sırasıyla şu şekildedir;

- I. Grup: Uzaktan Algılama ile Klasik yöntemlerle ürün tahmini
- II. Grup: Uzaktan Algılama ile Makine öğrenmesi yaklaşımıyla ürün tahmini

2.1. I. Gruba Ait Literatür Çalışmaları

Kandemir (2010) uzaktan algılama yöntemlerinde NDVI indeksleri ile doğal bitki örtüsünün çeşitleri açısından dağılımı arasındaki ilişkiyi araştırmıştır. Bu çalışma için tür çeşitliliği bakımından zengin olan Karaburun Yarımadası araştırma alanı olarak seçilmiştir. 111 alana ait bitki türü kompozisyonuna ait veriler, ASTER uydusu görüntülerinden oluşturulan NDVI görüntüsü ile ilişkilendirilmiştir. Yaprak yoğunluğu ile bitki indeksi arasında pozitif korelasyon gözlemlenmekle birlikte bitki indeksinin tek başına tür tahmininde kullanılmasının hatalı sonuçlar doğuracağı kanaatine varılmıştır.

Aydoğdu ve ark. (2011) mera bitki örtüsü uydu görüntülerinin NDVI ile izlenmesini araştırmışlardır. Bitki örtüsünün yeşillenmesinden sararmasına kadar olan değişimleri, NDVI yardımıyla tespit ederek gözlemlenmiştir. NDVI, arazide bulunan aktif biokütlenin miktarını göstermektedir. Bu çalışmada mera bitki örtüsünün yıl içindeki mevsimsel değişimlerinin izlenmesi amacıyla Spot-Bitki Örtüsü görüntüleri ve mera ziyaretlerinden elde edilen koordinatlı veriler kullanılmıştır. Uydu görüntüleri 1998-2009 yıllarını kapsamakta ve her yıl için 10 günlük 36 NDVI verisini kullanmıştır. Elde edilen bulgulara göre uydu görüntüleri ile mera bitki örtüsü değişiminin izlenebilmesinin başarılı bir şekilde yapılabileceği sonucuna varılmıştır.

Çelik ve Sönmez (2013) tarafından Kızıltepe ilçesinin arazi örtüsünün değişimlerine ilişkin MODIS NDVI verileri hesaplanmıştır. Bu çalışmada kırmızı ve

yakın kızıl ötesi bandı kullanılarak elde edilen, 16 günlük zamansal çözünürlüğü ve 250 m'lik mekânsal çözünürlüğe sahip MODIS NDVI verileri kullanılmıştır. Bu verilerden elde edilen sonuçlara göre, Kızıltepe'de 2001 yılının ağustos ayında yaklaşık 41 bin hektar olan yüksek biomas etkiye sahip tarım sahaları, 2006 yılında 72 bin hektara yükselmiş ve 2011 yılında 83 bin hektar civarına yükseldiğini gözlemlemişlerdir.

Gündoğdu (2018) Buğday ekili parsellerde NDVI değerlerinin konumsal ve zamana bağlı değişiminin belirlenmesini araştırmıştır. Bu çalışma Uludağ Üniversitesi Ziraat Fakültesi çiftlik arazisinde 2015-2016 üretim döneminde Pehlivan çeşidi buğday ekili alanlarda NDVI değerlerinin zamana ve konuma göre değişimini belirlemeyi amaçlamıştır. Farklı tarihlerde çekilmiş Landsat-8 görüntüleri bu çalışmada kullanılmıştır. Parsel bazında yapılan değerlendirme sonucunda parsel içerisinde NDVI değerlerinin homojen bir dağılım göstermediği görülmüştür.

Gandhi ve ark. (2015) uzaktan algılamayı kullanarak bitki örtüsü değişimini gözlemlemişlerdir. Çalışmada, çoklu kaynak sınıflandırmasını gerçekleştirmek için Landsat tematik haritalandırıcı (Thematic Mapper, TM) görüntüsünden NDVI veri katmanlarıyla birlikte uzaktan algılama verileri kullanılmıştır. Çalışmada, uydu görüntüsünün analizi için NDVI tabanlı gelişmiş bir Değişim Tespit yöntemi sunmuşlardır. NDVI metodu kullanılarak 0.1, 0.15, 0.2, 0.25, 0.3, 0.35, 0.4 ve 0.5 gibi farklı NDVI eşik değerlerinde, bitki örtüsü yoğunluğu değişimi hesaplanmıştır. Simülasyon sonuçları, NDVI'nin karar vermede politika yapıcılar için son derece yararlı olan görünür alanın yüzey özelliklerini tespit etmede oldukça yararlı olduğunu göstermektedir. Deneysel çalışmadan sonra, orman veya çalı arazisi ile çorak arazisi örtü tipleri yaklaşık % 6 ve % 23 oranında azaldığı; tarım alanları, yapılaşma alanları ve su alanlarının ise sırasıyla %19, %4 ve % 7 oranında arttığı gözlemlenmiştir.

Doğan ve ark. (2014) tarafından Tokat ili bitki örtüsü yoğunluğu uydu görüntüleri ile araştırılmıştır. Bu çalışmada Tokat ili bitkisel tarım arazilerinin 2000 yılındaki dağılımı LANDSAT-7 gelişmiş tematik haritalandırıcı (Enhanced Thematic Mapper Plus, ETM+) görüntüleri ve NDVI kullanılarak oluşturulmuştur. NDVI sınıflandırılmasının doğruluk oranı, çalışma sahasının genelinde 103 farklı koordinat noktalarından alınan veriler kullanılarak hesaplanmıştır. Doğruluk değerlendirmesi NDVI sınıflarına ait veri doğruluk yüzdesini % 86.45 olduğunu hesaplanmıştır. Sonuçlar NDVI değerlerinin, sınıflandırılmada kullanılabileceğini ortaya koymuştur.

2.2. II. Gruba Ait Literatür Çalışmaları

Birçok araştırmacı tarafından, uzaktan algılama yoluyla mahsul tanımlamada makine öğrenimi yöntemi kullanılarak yapılan çalışma konuları ele alınmıştır.

Ngugive ark. (2011) Uzaktan algılanan verilerin geleneksel piksel tabanlı analizi, piksel heterojenliği, karışık pikseller, spektral benzerlik ve ürün deseni değişkenliği nedeniyle bazı mahsullerin yanlış tanımlanmasına neden olur. Bu sorunları nesne tabanlı görüntü analizi (OBIA) teknikleri kullanılarak aşılabileceğini savunmuşlardır. Yaklaşımlarında, üç farklı büyüme mevsimi döneminde (ilkbahar ortası, yaz başı, yaz sonu) toplanan ASTER uydu sahnelerinin görünür (R), yakın kızılötesi (NIR) ve kısa dalga kızılötesi (SWIR) bantlarından türetilen çeşitli bitki örtüsü endekslerini (VI) ve dokusal özellikleri araştırmışlardır. Çalışmayı, ABD'nin Kaliforniya eyaletindeki Yolo İlçesinin tarım alanında yetiştirilen 13 mahsul üzerinde yapmışlardır. Model tasarımlarını, iki bağımsız eğitim ve doğrulama veri kümesi kullanılarak dört farklı senaryo üzerinden en iyi DT'ler, seçmişler. Daha sonra, seçilen DT, tüm ekim arazisinin tematik sınıflandırması için kullanarak haritalama, %79 genel doğruluk bildiren bağımsız test veri setine hata matrisi yöntemi uygulanarak değerlendirilmiştir. Yaz sonu görüntülerinden çıkarılan özellikler, sınıflandırma modeli geliştirmeye yaklaşık %60 katkıda bulunurken, ilkbahar ortası ve yaz başı görüntüleri sırasıyla yaklaşık %30 ve %10 katkıda bulunduğu hesaplanmıştır. Normalleştirilmiş Bitki Örtüsü İndeksi (NDVI), arazideki yeşil bitki örtüsünün varlığı ve canlılığına dayalı olarak ana ürün gruplarını belirlemek için kullanılmış ve modellere yaklaşık %50 katkıda bulunulmuş. OCIM yöntemi, incelenen mahsullerin fiziksel özelliklerine dayalı yorumlanabilir kurallar kullanılarak oluşturulmuş ve nesne tabanlı özellik seçimi ve mahsul tanımlamada başarılı olmuşlardır.

Çölkesen ve Kavoğlu (2011) çalışmalarında temel olarak nesne-tabanlı yaklaşımla sınıflandırılmasını WorldView2 görüntüsünü kullanarak ve arazi örtüsünü gösteren tematik harita üretimi problemini incelemişler. Özellik seçiminin sınıflandırma yaklaşımlarının üzerindeki etkisini araştırmışlardır. Filtreleme tabanlı özellik seçimi yöntemlerinden ki-kare, kazanç oranı ve ReliefF algoritmalarını kullanmışlardır. Veri setlerinin sınıflandırılması ve tematik harita oluşturulmasında kernel tabanlı destek vektör makineleri (DVM), karar ağaçlarını (DT) esas alan rastgele orman (RO) ve klasik en yakın komşuluk (K-NN) algoritmasını kullanmışlardır. Elde edilen veri sonuçları doğruluk yüzdelerinin karşılaştırılmasının yanında veri seti

büyükliğünün azalması ile elde edilen doğruluk yüzdeleri arasındaki farklılıkların istatistiksel sonuçları Wilcoxon işaretli sıralar testi kullanılarak test etmişlerdir.

Wardlow ve ark. (2008), melez bir sınıf kullanarak altı ana Akdeniz mahsulünün (kışlık tahıllar, pirinç, mısır, yonca, meyve ağaçları ve diğer mahsuller) zamansal imzalarının haritalanması ve izlenmesi için bir yöntem bilim ve 2002-2008 yıllarını kapsayan Landsat görüntüsü kullanılmıştır. Çalışmacılar, yüksek doğruluk elde etmek için çok zamanlı bir yaklaşımın gerekli olduğu sonucuna varmışlardır ve mahsul fenolojisinin sınıflandırma metodolojisine dâhil edilmesini tavsiye etmişlerdir. Ayrıca bir karar ağacı (DT) algoritması kullanarak dört ana sınıfı (çıplak toprak, yıllık bitki örtüsü, çıplak topraktaki ağaçlar ve yıllık alttaki ağaçlar) belirlemek için sekiz Landsat görüntüsünden oluşan bir zaman serisi kullanarak ayrıntılı bir ekin tipolojisinin kullanmışlardır. Normalleştirilmiş Bitki Örtüsü İndeksi (NDVI) profillerinin analiz etmek için Orta Çözünürlüklü Görüntüleme Spektro radyometresi (MODIS) zaman serisini kullanmışlardır. Sınıflandırma olarak karar ağacı (DT) yöntemini kullanmışlar ve bu yöntemin sınıf içi değişkenlik sonraki nesne tabanlı sınıflandırma prosedüründe daha etkili olduğunu gözlemlemişlerdir.

Yıldız ve ark. (2012) Türkiye arazi bitki örtüsünün NDVI indeksleri ile zamansal ve mekansal analizini yapmışlardır. Bu çalışmada Türkiye genelinde bitki örtüsü oluşumunun dağılımı, bitkilerin gelişmeye başlama tarihi ve en yüksek değerdeki yoğunluğa erişme tarihi gibi zamansal değişimi üzerindeki etkinin incelenmesi amaçlanmıştır. Bu çalışmada Türkiye'yi kapsayan SPOT-Bitki Örtüsü NDVI değerleri veri olarak kullanılmış ve verilerin işlenmesi VAST yazılımı ile yapılmıştır. Hesaplama sonucunda elde edilen NDVI verileri ile bitki örtüsü gelişimi başarılı bir şekilde hesaplanıp analiz edilebileceği görülmüştür.

Kumar ve ark. 2015, mahsul sınıflandırma çalışmaları için geliştirilmiş özellikleri ve yetenekleri ile son derece uygun bir uydu olan Resourcesat-2 kullanmışlardır. Destek vektör makinesi (DVM), yapay sinir ağı (YSA) ile elde edilen göreceli doğrulukları karşılaştırmak için 5.8 m uzamsal çözünürlüğe sahip sensörlerinden biri olan doğrusal görüntüleme ve kendi kendini taramadan (LISS IV) gelen verileri kullanmışlardır. Çeşitli mahsullerin ve mahsul olmayanların sınıflandırılması için, Uttar Pradesh, Hindistan'ın Varanasi bölgesinin bir bölümünü kapsayan spektral aç haritalama (SAM) algoritmalarını kullanmışlardır. Ayrılabilirlik analizi, eğitim örneklerinin kalitesini değerlendirmek için kategoriler arasında dönüştürülmüş bir sapma (TD) yöntemi kullanılarak gerçekleştirmişlerdir. Bu

çalışmanın sonucu, LISS IV sensör verilerini kullanan sınıflandırma için SAM ile karşılaştırıldığında DVM ve YSA algoritmalarının daha iyi performans gösterdiğini gözlemlemişlerdir.. DVM ve YSA ile elde edilen genel doğruluklar sırasıyla% 93.45 ve% 92.32 iken, SAM algoritması ile hata matrisi analizi ile% 74.99 gibi daha düşük doğruluk elde etmişlerdir. DVM, YSA ve SAM sınıflandırma algoritmalarından elde edilen sonuçlar, uydu verilerinin elde edildiği aynı gün saha ziyareti ile elde edilen yer gerçeği bilgileriyle doğrulamışlardır.

Zheng ve ark. (2015) Çalışmalarında, destek vektör makinelerinin (DVM'ler) Phoenix Aktif Yönetim Alanındaki karmaşık bir ekim sisteminde çeşitli ekin türlerini ayırt etme potansiyelini araştırdılar. DVM'leri Landsat zaman serisi Normalleştirilmiş Bitki Örtüsü İndeksi (NDVI) verilerine, iki farklı yaklaşımla seçilen eğitim veri kümelerini kullanarak uygulamışlardır: tabakalı rastgele yaklaşım ve yerel bilgiyi kullanan akıllı seçim yaklaşımı. DVM modelleri, her iki eğitim veri kümesi için genel doğruluk oranı $> \% 86$ olan dokuz ana ürün türünü etkili bir şekilde sınıflandırmışlardır. Sonuç olarak, akıllı seçim yaklaşımının eğitim seti boyutunu azaltabildiğini ve tabakalı rastgele yaklaşıma göre daha yüksek genel sınıflandırma doğruluğu elde edildiğini göstermişlerdir. Akıllı seçim yaklaşımı, referans verilerinin kullanılabilirliği sınırlı ve farklı sınıflar arasında dengesiz olduğunda özellikle yararlanılmıştır. Çalışmada, kurak ve yarı kurak bölgelerde zaman içinde mahsul türlerini ve mahsul modellerini sistematik olarak izlemek için çok zamanlı Landsat görüntülerinden yararlanma potansiyelini göstermişlerdir.

Kwak ve Parkı (2019) uydu görüntülerinden çok daha yüksek uzaysal ve zamansal çözünürlüklerde tematik bilgi sağlayabilen insansız hava aracı (İHA) görüntüleri, ürün sınıflandırmasında kullanmışlardır. Zaman serisi İHA görüntüleri ve rastgele orman ve destek vektör makinesi dahil olmak üzere makine öğrenimi sınıflandırıcıları ile mahsul sınıflandırması için gri düzey eş oluşum matrisi (GLCM) tabanlı doku bilgilerinin potansiyelini araştırmışlardır. Çalışma alanı olarak Kore'nin Anbandegi bölgesinde mahsul sınıflandırmasına ilişkin bir alanı tercih etmişlerdir. mahsul sınıflandırması için büyüme dönemi İHA görüntüleri, Ağustos İHA görüntüsü kullanıldığında, doku bilgilerinin kullanılması sınıflandırma performansını önemli ölçüde farklılık gösterdiğini gözlemlemişlerdir. GLCM'den çıkarılan doku özelliklerini kullanarak destek vektör makinesi sınıflandırıcısının genel doğruluğunda %7.72'lik bir iyileşme hesaplamışlardır. Bu sonuçlar, özellikle zaman serisi İHA görüntülerinin elde edilmesi zor olduğunda ve ürün sınıflandırması için yalnızca bir İHA görüntüsü

kullanıldığında, ultra yüksek uzaysal çözünürlüklü İHA görüntülerinin sınıflandırılması için doku bilgilerinin yararlılığını göstermektedir.

Lebrini ve ark. (2020), Sentinel-2A (S2) zaman serilerinden türetilen fenolojik göstergelerin potansiyeli, hem ekin alanlarını hem de ürün türlerini tanımlamaya izin veren temel değişkenleri keşfetmek için değerlendirilmiştir. Türetilmiş S2 fenolojik ölçütlerine ve uyumlu bitki örtüsü indekslerine (VI) dayalı olarak, Random Forest (RF) sınıflandırıcı aracılığıyla farklı ürün türlerini ayırt etmek için 10 özellik seti geliştirilmiş ve değerlendirilmiştir. VI veri tabanlı sınıflandırmalar arasındaki karşılaştırma, NDVI ve EVI2 fenolojik setlerinin, mahsul türlerini RENDVI verilerine kıyasla daha doğru bir şekilde tanımlayabildiğini ve tanımlayabildiğini göstermiştir. Genel olarak, ayrı ayrı kullanılmak yerine yerleştirilmiş VI ve fenolojik özelliklerin birlikte kullanılmasıyla en iyi performansları elde edildiğini göstermişlerdir. Ayrıca, optimum özellikleri kullanmanın sonucu, % 88'lik genel doğruluk ve 0.84 kappa ile 10 özellik seti arasında en doğru olarak hesaplamışlardır.

Kobayashi ve ark. (2019) Görünür, yakın kızılötesi ve kısa dalga kızılötesi (SWIR) dalga boyu bölgelerini kapsayan 13 bantlı multispektral bir sensör olan Sentinel-2A Multispectral Instrument (MSI), çok sayıda bitki örtüsü indeksi kullanmışlardır. Farklı dalga boylarında spektral ölçümlerin kombinasyonları olan spektral indeksler önceki çalışmalarda kullanılmışlar. Bu çalışmada, MSI verilerinden 91 yayınlanmış spektral indeks hesaplamışlardır. Bunlara ek olarak, sınıflandırma algoritmaları, doğru haritalar oluşturmak için gerekli ve rasgele ormanlar sınıflandırıcısı, beş hiper parametreye sahip olanlardan biri olduğu gözlemlenmiştir. Sınıflandırma doğruluğundaki gelişmeler, 4 bantta ve 8 spektral indekste yansıma bazında %93.1 genel doğruluk yüzdesi elde ettiği doğrulamışlardır.

Mazzia ve ark. (2020) Bu çalışmada, Akdeniz iklimine sahip Güney Afrika'nın Western Cape Eyaletindeki iki farklı bölge kullanılmıştır. Sentinel-2 uydusundan belirli dönemlere ait görüntülerini kullanarak ürün tipi haritalama için DVM (destek vektör makinesi), DT (karar ağacı), k-NN (k-en yakın komşu), RF (rastgele orman) ve ML (maksimum olasılık) olmak üzere birkaç makine öğrenimi sınıflandırıcısının performansını değerlendirmişlerdir. Sınıflandırma sonuçları, genel doğruluklar ve kappa katsayıları karşılaştırılarak analiz edilirken, McNemar' testi ve ANOVA (varyans analizi), deneyler arasındaki doğruluk farklılıklarının istatistiksel önemini değerlendirmek için kullanılmıştır. Dönemsel olarak incelenen görüntülerin doğruluk oranları karşılaştırıldığında hasat öncesi dönemine ait sınıflandırmanın, DVM ve RF

kullanımıyla elde edilen sınıflandırma doğruluk oranı % 77.2 olarak, mahsulleri doğru bir şekilde tanımlama potansiyeline sahip olduğunu göstermişlerdir.

Chakhar ve ark. (2020) Landsat-8 ve Sentinel-2A bilgilerini birleştirmenin sulu mahsul sınıflandırması için kullanmışlardır. Ayrıca İspanya'nın güneydoğusundaki yarı kurak bir bölgede sulanan mahsulleri sınıflandırmak için 22 parametrik olmayan sınıflandırma algoritmasının sağlamlığını ve verimliliğini değerlendirmişlerdir. Veri olarak 12 farklı ürün için (NDVI) ve bir kalibrasyon testi veri seti oluşturmuşlardır. En yakın komşu yöntemler ve destek vektör makineleri, sınıflandırma yöntemleri kullanmışlardır. Bu sınıflandırma yöntemlerinde F1 skoru% 90'a yakın olmasına rağmen, bahar mahsulleri için bazı yanlış sınıflandırmalar rastlamışlardır. (örneğin, arpa, buğday ve bezelye).

Mmamokom ve ark. (2019) Bu çalışmada, ürün türü haritalama için DVM (destek vektör makinesi), DT (karar ağacı), k-NN (k-en yakın komşu), RF (rastgele orman) ve ML (maksimum olasılık) olmak üzere birkaç makine öğrenimi sınıflandırıcısının performansını kullanmışlardır. Uzaktan algılama görüntüsü olarak Sentinel-2 resimleri kullanılmıştır. Farklı görüntü seti kombinasyonları ile dört deney gerçekleştirilmiştir. Tek tarihli (tek zamansal) görüntüler, tek tarihli görüntülerden seçilen beş görüntünün kombinasyonları, manuel olarak seçilen beş resim ve hasat öncesi görüntüler kullanılmıştır. Sınıflandırma sonuçları, hasattan sekiz hafta öncesine kadar DVM ve k-NN kullanımıyla iyi sınıflandırma doğruluklarını (% 78.3) elde etmişlerdir. Bu sonuçlar, hasat öncesi görüntülerinin mahsulleri doğru bir şekilde tanımlama potansiyeline sahip olduğunu göstermektedir.

Htitiou ve ark (2020) Bu çalışmada, Sentinel-2A (S2) fenolojik ölçütlerine ve uyumlu bitki örtüsü indekslerine (VI) dayalı olarak, Random Forest (RF) sınıflandırıcı aracılığıyla farklı ürün türlerini ayırt etmek için 10 özellik setini değerlendirmişlerdir. VI veri tabanlı sınıflandırmalar arasındaki karşılaştırma, NDVI ve EVI2 fenolojik setlerinin, mahsul türlerini RENDVI verilerine kıyasla daha doğru bir şekilde tanımlayabildiğini gözlemlemişlerdir. Sınıflandırma sonucu, %88'lik genel doğruluk ve 0.84 kappa ile 10 özellik seti arasında en doğru olduğu gözlemlenmiştir.


Önermiş olduğumuz çalışmada Landsat-8 görüntülerinden elde edilen NDVI değerleri yardımıyla tarımsal ürünlerin (buğday ve mercimek) otomatik tespiti farklı makine öğrenme yöntemleri kullanılarak yapılmıştır. Yapmış olduğumuz bu çalışmanın literatüre ana katkısı; tarım ürünlerinin tespitinde kullanılan gözlemsel yöntemle doğruluk yüzdesinin arttırılmış olarak daha isabetli tahminler elde edilmesini

sağlamasıdır. Böylece yanlış tespit edilen alanların kontrol edilmesinde zamansal ve ekonomik açıdan tasarruf edilmesini sağlamış olmasıdır.

Ayrıca bu çalışmada aynı ürünlere ait farklı tarihleri kapsayan NDVI değerlerinden oluşan verilerin karşılaştırılması yapılmıştır. Yapılan karşılaştırma sonucunda, tarımsal ürünlerin NDVI değerleri temel alınarak yapılan çalışmalarda, bitkilerin klorofil oranlarının yüksek olduğu yeşerme dönemine ait verilerden elde edilen doğruluk yüzdesinin, uygulanan bütün makine öğrenmesi yöntemlerinde büyük bir farkla klorofil oranının düşük olduğu hasat döneminden yüksek hesaplandığı gözlenmiştir. Bunun nedeni olarak NDVI değerinin hesaplanırken kırmızı banda ait ışının emilme oranının yüksek olması gösterilebilir. Bu göz önüne alınarak üzerinde çalışma yapılacak tarımsal ürünün klorofil oranının yüksek olduğu döneme ait uydu görüntüsünün kullanılarak çalışma yapılması tavsiye edilebilir.

3.MATERYAL VE YÖNTEM

Tezde uygulanan yöntem ve araştırma teknikleri bu kısımda anlatılmıştır. Önerilen çalışmaların oluşumu birkaç aşamada yapılmaktadır. Bu aşamalar sırasıyla Çalışma Alanının Belirlenmesi, Veri Toplama, Önilem ve Özellik Çıkarma basamaklarından oluşmaktadır. Şekil 3.1’de, bu çalışmada önerilen bitki örtüsü indeksi belirleme modeline ait sistemin blok diyagramı verilmektedir.



Şekil 3.1. Seçilen noktadaki ürünü belirleme modeline ait blok diyagramı

3.1. Çalışma Alanı

Çalışma alanı olarak, Pilot tarım alanının seçilmesinde Batman Tarım Müdürlüğü'nün denetimi altında bulunan Batman Merkeze bağlı Bıçakçı Köyü sınırlarında 2x2 km² alanı kaplayan mercimek ve buğday tarım ürünlerinin ekili olduğu tarım arazisi çalışma için uygun olarak görülmüştür. Çalışma alanının eğimi yaklaşık olarak %2.4 ve ortalama yükseltisi 540 m'dir. Yıllık ortalama sıcaklık değeri, yaz aylarında 36.5 °C, kış aylarında ise 6.8 °C göstermektedir ve ortalama yıllık sıcaklık 25.3 °C'dir. Ortalama yıllık yağış değeri ise 386.0 mm'dir. Bu tarımsal arazi ait farklı uydu görüntüsü incelenmiş olup Google Earth üzerindeki konumunu belirten harita Şekil 3.2'de gösterilmiştir.



Şekil 3.2. Google Earth çalışma alanı konumu

Şekil 3.3'de görüldüğü üzere, Google Earth görüntüsü kullanılarak çalışmalarımızın yapıldığı arazi ve bu araziler üzerindeki parsellemeler alınacak koordinatların doğru alınması için renklendirilmiş bir şekilde sınır hatları belirgin bir hale getirilmiştir.



Şekil 3.3. Google Earth çalışma alanı parsellenmiş görünümü

3.2. Veri Toplama

Bu tez çalışması için Landsat - 8 uyduya ait iki ayrı görüntü kullanılmıştır. Birinci uydu görüntüsü 2018 yılı ürün gelişim dönemine ait 6 Mayıs tarihli uydu görüntüsüdür. İkinci uydu görüntüsü ise 30 Ağustos tarihli görüntüdür.

3.2.1. Landsat

Landsat uyduları, 1970’li yılların başından bu yana sürekli olarak Dünya’nın multispektral görüntülerini sağlamıştır. Bu çabalar sayesinde büyük bir veri kaydı elde bulunmaktadır. Dünya toprak yüzeyini ve insanların çevre üzerindeki etkisini daha iyi anlamak için bu veri kaydı çeşitli disiplinlerde kullanılmıştır. Landsat verileri çeşitli devlet, kamu, özel ve ulusal güvenlik uygulamalarında kullanılmıştır. Bu uygulamalar arasında toprak ve su yönetimi, küresel değişim araştırması, petrol ve mineral arama, tarımsal verim tahmini, kirlilik izleme, arazi yüzeyindeki değişimin tespiti ve kartografik haritalama yer almaktadır (Anonim 2018).

Landsat-1, sivil amaçlı kullanılan ilk yeryüzü gözlem uydusu, 23 Temmuz 1972’de Amerikan Uzay Merkezi tarafından yörüngesine atılmıştır. Sonraki yıllarda Landsat serisinden altı uydu daha uzaya fırlatılmıştır. Landsat uydusuna 1970’li yıllarda yerleştirilmiş olan Multi spektral Tarayıcı Sistem (Multispectral Scanner System, MSS) algılayıcısı sayesinde görünür ve yakın kızılötesinde 4 bantta 60m konumsal çözünürlükte veri oluşturulabilmiştir. 1980’li yıllarda ise TM algılayıcısının geliştirilmesiyle çözünürlük mesafesi 30m seviyesine yükseltilmiş, bant sayısı ise 3adet daha arttırılarak 7’ye çıkarılmıştır. Son Landsat sistemlerinde TM algılayıcısı yerine

benzer özellikli ETM+ algılayıcısı kullanılmıştır. Landsat-7'de termal bant çözünürlüğü 60 m'ye yükseltilmiş ve 15 m konumsal çözünürlüğe sahip bir pankromatik bant ilave edilmiştir. Özellikle 1990'lı yılların başından itibaren teknolojik gelişmelere paralel olarak birçok ülke tarafından çeşitli özellikte uydu programları geliştirilerek kullanılmaya başlanmıştır (Çölkesen ve Kavzoğlu 2011).

En son piyasaya sürülen uydu ise Landsat-8 uydusudur. Bu çalışmada Landsat-8 uydusuna ait görüntüler kullanıldığı için bu uydu verileri üstünde durulmuştur. Çizelge 3.1'de Landsat uydularına ait bilgiler verilmiştir (Anonim 2018).

Çizelge 3.1. Landsat Programında Bulunan Uyduların Özellikleri

S. N	Uydu Adı	Görev Başlangıcı	Görev Bitiş	Algılayıcı Tipi	Konumsal Çözünürlük
1	Landsat -1	23 Temmuz 1972	6 Ocak 1978	MSS	60 m
2	Landsat -2	22 Ocak 1975	25 Şubat 1982	MSS	60 m
3	Landsat -3	5 Mart 1978	31 Mart 1983	MSS	60 m
4	Landsat -4	16 Temmuz 1982	31 Mart 1983	MSS, TM	30 m - 60 m
5	Landsat -5	1 Mart 1984	5 Haziran 2013	MSS, TM	30 m - 60 m
6	Landsat -6	5 Ekim 1993	5 Ekim 1993	ETM	15 m – 30 m
7	Landsat -7	15 Nisan 1999	Hala aktif	ETM+	15 m – 30 m
8	Landsat -8	11 Şubat 2013	Hala aktif	OLI, TIRS	15 m – 30 m
9	Landsat -9	2020 Aralık (beklenen)	-	OLI-2, TIRS-2	-

Landsat Uydu Görüntüsündeki Bantlar ve Özellikleri:

- TM-1 (Mavi): Mavi renge, su yüzeylerine, nemli alanlara hassastır.
- TM-2 (Yeşil): Yeşil renge, yeşil renkli bitkilere hassastır.
- TM-3 (Kırmızı): Kırmızı renge, demir içeren minerallere hassastır.
- TM-4 (Yakın Kızılötesi): Klorofile hassastır.
- TM-5 (Orta Kızılötesi): Organik topraklardaki hidroksil iyonuna, karbonit minerallerine ve bitkilerin içerdiği suya hassastır.

- TM-7 (Orta Kızılötesi): Hidroksil iyonuna ve karbonit minerallerine hassastır.
- TM-6 (Termal Kızılötesi): Isı yayan materyallere hassastır.
- TM-9 (Pankromatik): Mekânsal çözünürlüğü diğer bantlara göre daha yüksektir (15m.), (Karahanlı 2010).

3.2.1.1. Landsat-8 Uydusu

Landsat-8, 11 Şubat 2013 tarihinde piyasaya sürülen bir Amerikan Dünya gözlem uydusudur. Landsat programındaki sekizinci ve yörüngeye başarıyla ulaşan yedinci uydudur. Başlangıçta NASA ve Amerika Birleşik Devletleri Jeolojik Araştırmaları (USGS) arasındaki işbirliği Landsat Veri Sürekliliği Misyonu (LDCM) olarak adlandırılmıştır. NASA, yer üstü sistemlerin geliştirilmesini sağlamış ve devam eden misyon operasyonlarını yürütürken, USGS, fırlatma aracının geliştirilmesi, görev sistemleri mühendisliği ve devralınmasını sağlamıştır (Anonim 2013).

Landsat-8 uydusunun ana hedefi ve görevi şunlardır (Anonim 2013):

1. Dünya üzerindeki kara kütlelerinin 5 yıldan az olmayan bir süre boyunca mevsimsel kapsamını ortaya koyan orta çözünürlüklü (30 metre uzamsal çözünürlük) multispektral görüntü verilerini toplamak ve arşivlemek;
2. Landsat-8 verilerinin, daha önceki Landsat misyonlarından elde edilen satın alma geometrisi, kalibrasyon, kapsama özellikleri, spektral özellikler, çıktı ürün kalitesi ve zaman içinde arazi ve arazi kullanımı değişiklik çalışmalarına izin vermek için veri kullanılabilirliği açısından verilerle yeterince tutarlı olmasını sağlamak;
3. Landsat-8 veri ürünlerini, kullanıcıya hiçbir ücret ödmeden, ayrım gözetmeden dağıtmak.

Dünya'nın kara yüzeyine ve kutup bölgelerine 15 metreden 100 metreye kadar makul çözünürlükte görüntüler sunan Landsat-8 görünür, kızılötesi yakın, kısa dalga kızılötesi ve termal kızılötesi spektrumlarında çalışır. Landsat-8'de Operasyonel Arazi Görüntüleyici (Operational Land Imager, OLI) ve Termal Kızılötesi Algılayıcı (Thermal Infrared Sensor, TIRS) algılayıcıları kullanılmıştır (Anonim 2013).

3.2.1.2. Operasyonel Arazi Görüntüleyici –OLI

OLI dokuz spektral banttandır veri toplar. Dokuz grubun yedisi, önceki Landsat uydularında bulunan ve Landsat verileriyle uyumluluk sağlayan ve aynı zamanda ölçüm yeteneklerini geliştiren TM ve ETM + algılayıcılarıyla tutarlıdır. İki yeni spektral bant, derin mavi kıyı / aerosol bandı ve kısa dalga kızılötesi sirrus bandı dalgalarını toplar ve bilim adamlarının su kalitesini ölçmelerine ve yüksek, ince bulutların algılanmasının iyileştirmelerine olanak sağlar (Anonim 2013).

OLI, NASA'nın deneysel EO-1 uydusunda uçulan bir sensörün gösterdiği teknik bir yaklaşımı kullanarak geçmişteki Landsat sensörlerini geliştiriyor. OLI, dört aynalı bir teleskopa ve 12 bitlik kuantizasyona sahip bir itmeli süpürge sensörüdür. OLI, pankromatik bantın yanı sıra görünür, yakın kızılötesi ve kısa dalga kızılötesi spektral bantlar için veri toplar. Beş yıllık tasarım ömrüne sahiptir. Aşağıdaki grafik, OLI spektral bantlarını Landsat 7'nin ETM + bantlarıyla karşılaştırmaktadır. OLI, biri özellikle sirrus bulutlarını tespit etmek için, diğeri kıyı bölgesi gözlemleri için tasarlanmış iki yeni spektral bant sağlar (Alliance 2013).

Bu bantlara ait özellikler Çizelge 3.2'de belirtilmiştir (Anonim 2017).

Çizelge 3.2 OLI Spektral Bant Özellikleri

Spektral Bant	Dalga boyu	Çözünürlük
Band1 -Kıyı/ Aerosol	0.433 – 0.453µm	30 m
Bant 2- Mavi	0.450 – 0.515µm	30 m
Bant 3 – Yeşil	0.525 - 0.600 µm	30 m
Bant 4 – Kırmızı	0.630 – 0.680µm	30 m
Bant 5 - Yakın Kızılötesi	0.845 – 0.885µm	30 m
Bant 6 - Kısa Dalga Boyu Kızılötesi	1.560 – 1.660µm	30 m
Bant 7 - Kısa Dalga Boyu Kızılötesi	2.100 – 2.300µm	30 m
Bant 8- Pankromatik	0.500 - 0.680µm	15 m
<i>Bant 9 – Sirrus</i>	1.360 – 1.390µm	30

3.2.1.3. Termal Kızılötesi Algılayıcı - TIRS

TIRS, Landsat-8 uydusuna sonradan eklenmiştir. Algılayıcının gelişimini hızlandırmak için tasarım ömrü kısa tutulmuştur. Bu nedenle, TIRS sadece üç yıllık bir tasarım ömrüne sahiptir. NASA Goddard Uzay Uçuş Merkezi tarafından yaptırılan TIRS, termal görüntüleme gerçekleştirir ve su yönetimi için buharlaşma, transpirasyon (terleme) hızı ölçümleri gibi yeni ortaya çıkan uygulamaları destekler. TIRS odak düzlemi, Landsat programında bir ilk olan kızılötesi radyasyonu tespit etmek için GaA Quantum Well Infrared Photodetector dizilerini (QWIP olarak bilinir) kullanır (Anonim 2013).

TIRS, önceden Landsats 4–7'de bir geniş spektral bant tarafından kapsanan termal bölgede iki daha dar spektral bant için veri toplar. 100 m TIRS verileri, radyometrik, geometrik ve arazi düzeltmeli 12 bit veri ürünleri oluşturmak için OLI verilerine kaydedilir. Landsat 8'in günde 400 sahneyi USGS veri arşivine geri göndermesi gerekiyor (yakalamak için Landsat 7'den 150 daha fazlası gerekiyor). Landsat 8, düzenli olarak günde 725 sahne alıyor (ve Landsat 7, günde 438 sahne alıyor). Bu, küresel kara kütleleri için bulutsuz sahneler yakalama olasılığını artırır. Landsat 8 sahne boyutu, 180 km'lik bir yol boyunca 185 km'lik çapraz izdir. Nominal uzay aracı yüksekliği 705 km'dir. Landsat 8 veri ürünleri için 12 m veya daha iyi kartografik doğruluk (arazi etkilerinin telafisi dahil) gereklidir. (Alliance 2013)

Bu algılayıcının algıladığı bantlara ait özellikler Çizelge 3.3'de belirtilmiştir (Anonim 2013).

Çizelge 3.3. TIRS Spektral Bant Özellikleri

Spektral Bant	Dalga boyu	Çözünürlük
Bant 10 - Uzun Dalga Boyu Kızılötesi	10.30 - 11.30 μm	100
Bant 11 - Uzun Dalga Boyu Kızılötesi	11.50 - 12.50 μm	100

3.3. Ön İşlem


Bu tez çalışmasında 'Uzaktan Algılanmış Görüntü İndeksleriyle Nesne Tesbitinde makine Öğrenmesi Yaklaşımı' başlıklı yüksek lisans tezi kapsamında kullanılan Landsat - 8 uydusuna ait ön işlemlerden geçmiş 6 Mayıs 2018 ve 30 Ağustos 2018 tarihli görüntüleri kullanılmıştır. Bu iki uydu görüntüleri çeşitli ön işlemlerden geçirilmiştir.

3.3.1 Landsat-8 Görüntüsü Ön İşlemleri


Bu çalışma kapsamında kullanılan Landsat-8 uydu görüntüsü Amerikan Jeoloji Servisi (USGS) sitesinden radyometrik ve geometrik düzeltmesi yapılmış olarak indirilmiştir. Bu görüntü, Universal Transverse Mercator (UTM) koordinat sistemi dilim 35 ve WGS84 datumundadır. İndirilen görüntüden 11 bant elde edilmiştir. Daha sonra bu bantlar üzerinde belirli oranlamalar yapılmıştır. Bant oranlama, temelinde bir banttaki bir piksele ait gri renk değerini aynı pikselin başka bir banttaki değerine bölünmesi veya diğer matematiksel işlemler uygulanmasıyla yeni piksel değerlerinin elde edildiği bir görüntü zenginleştirme analiz yöntemidir. Bunun yanı sıra bu görüntü zenginleştirme yöntemi kullanılarak, bantlar arasındaki spektral özellikler zenginleştirilmiş ve görüntüler üzerindeki arazi engebelerinin etkisi de düşürülmüştür. (Gupta ve ark. 2015). Bantlar üzerinde yapılan NDVI hesaplamaları sonucunda elde edilen görüntülere QGIS programı kullanılarak koordinatlar aktarılmıştır.

QGIS yazılımında, bant bileşimi, bant oranlaması ve görüntü zenginleştirme yöntemleri verilere uygulanmıştır. Verilerin hesaplanması için kullanılacak Landsat-8 görüntülerine ait 11 banttan 4. ve 5. bantlar ait görüntüler QGIS programı ‘raster komutu’ kullanılarak NDVI değerlerinin hesaplanacağı her iki tarihe ait görüntüler oluşturulmuştur. Oluşturulan bu görüntülere daha önceden Google Earth üzerinde belirlemiş olduğumuz 96 koordinat noktası QGIS programı ‘Katman Ekle komutu’ kullanılarak eklenmiştir. Ve her bir koordinat noktasına karşılık gelen NDVI değeri hesaplanmıştır.


Pilot alana ait 6 Mayıs 2018 ve 30 Ağustos 2018 tarihlerine ait görüntünün ham görünüm Şekil 3.4.- 3.6’de ve Landsat-8 verisi programda okunduğu zaman karşımıza Çizelge 3.2. ve Çizelge 3.3.’de belirtilen 11 farklı spektral banda ait görüntüler Şekil 3.5 - 3.7’de gösterilmiştir.




Şekil 3.4. Pilot Alana ait 06.05.2018 tarihli, Landsat-8 uydu ham görüntüsü.




a) Bant 1 görüntüsü




b) Bant 2 görüntüsü




c) Bant 3 görüntüsü




d) Bant 4 görüntüsü




e) Bant 5 görüntüsü



f) Bant 6 görüntüsü




g) Bant 7 görüntüsü




h) Bant 8 görüntüsü



ı) Bant 9 görüntüsü




i) Bant 10 görüntüsü




j) Bant 11 görüntüsü


Şekil 3.5. 06.05.2018 Tarihli Landsat-8 uydusunun 11 Bandına ait görüntüleri




Şekil 3.6. Pilot Alana ait 30.08.2018 tarihli, Landsat-8 uydu ham görüntüsü




a) Bant 1 görüntüsü




b) Bant 2 görüntüsü




c) Bant 3 görüntüsü




d) Bant 4 görüntüsü




e) Bant 5 görüntüsü



f) Bant 6 görüntüsü




g) Bant 7 görüntüsü




h) Bant 8 görüntüsü



ı) Bant 9 görüntüsü



i) Bant 10 görüntüsü



j) Bant 11 görüntüsü

Şekil 3.7. 30.08.2018 Tarihli Landsat-8 uydusunun 11 Bandına ait görüntüleri

3.4.Özellik Çıkarımı


Yeryüzündeki bitki çeşitliliği ve bitki örtüsü yoğunluğunu uzaktan algılama sistemlerini kullanarak gözlemlemek mümkündür. Bunun içinde bitki örtüsü indeksleri kullanılmaktadır. Bu çalışmada aynı tür bitki örtüsüne ait iki farklı tarihte alınan görüntüye ait bitki indeksi incelenmiştir. İlk olarak bitki örtü indeksi incelenecek olan tarım arazisi üzerinde ekili olan ürünlerin, buğday ve mercimek, yeşerme dönemi olan mayıs ayı içerisinde alınan uydu görüntüsüne ait kullanılan NDVI'dir. İkinci olarak incelenen bitki örtüsü indeksi ise tarım arazisi üzerinde ekili olan ürünlerin hasat dönemi olan ağustos ayı içerisinde alınan uydu görüntüsüne ait kullanılan NDVI'dir.

Tarım ürünü olarak seçilen buğday ve mercimek yetiştirme- hasat döneminin yakın olmasından kaynaklanan benzerliklerinden ötürü uydu görüntülerinde yaymış oldukları klorofil yansıma dalga boylarının piksel bazında yakın olmasından dolayı ürünün tahmin edilme doğruluk oranı düşük olmaktadır. Bu ürünlerin ayırt edilmesindeki zorluğun makine öğrenmesi ile aşılabilmesi ve tahmin doğruluk oranını yükseltmek için bu iki tarım ürünü seçilmiştir.

3.4.1.Normalize Edilmiş Fark Bitki Örtüsü İndeksi (NDVI)

Bitki örtüsü yoğunluğunu belirlemek için birçok yöntem geliştirilmiştir. NDVI en çok kullanılan yöntemlerden bir tanesidir. NDVI yönteminde elektromanyetik spektrumunun görünür ve yakın kızıl ötesi bölgeleri kullanılmıştır. Güneş ışığı nesnelere çarptığında, bu spektrumun belirli dalga boyları emilir ve diğer dalga boyları yansıtılır. Bitki yapraklarındaki pigment klorofil, fotosentezde kullanım için görünür ışığı (kırmızı, 0.4 μm – 0.7 μm) güçlü bir şekilde emer. Öte yandan, yaprakların hücre yapısı kızıl ötesi ışığı kuvvetle yansıtmaktadır (0.7 μm – 1.1 μm). Bir bitkinin yaprakları ne kadar fazlaysa, bu ışık dalga boyları o kadar fazla etkilenir (Weier ve Herring 2000). Bu bilgiler doğrultusunda NDVI formülü Eşitlik 3.1'deki şekilde tanımlanmıştır (Rouse ve ark.2017).

$$NDVI = \frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + \rho_{RED}} \quad (3.1)$$



Şekil 3.8. Yeşerme dönemi bitki örtüsü (solda) ve hasat dönemi bitki örtüsünün (sağda) görünür (visible) ve yakın kızılötesi (near infrared) ışığa karşı duyarlılığı hesaplaması (Çizim : Robert Simon)

Eşitlikte bulunan ρ_{NIR} ve ρ_{RED} sırasıyla yakın kızılötesi ve kırmızı(görünür) bantlara ait yansıma değerleri ifade eder.

Şekil 3.8. de gösterildiği üzere, NIR ışık spektrumun yakın kızılötesi dalga boyunu ($0.851 - 0.879 \mu m$), RED ise kırmızı bölge dalga boyunu ($0.636 - 0.673 \mu m$), NDVI (birimsiz) ise vejetasyon indeks değerini temsil etmektedir (Anonim, 2018). NDVI değerleri teorik olarak (-1) ile $(+1)$ arasında değişmektedir. Yeşil bitki örtüsünün fazla olduğu alanlarda indeks değeri $+1$ 'e doğru yaklaşırken, bulutlar, su ve kar düşük -1 yaklaşan NDVI indeks değerlerine sahiptir. Çıplak toprak ve zayıf bitki örtüsü durumunda ise sifıra yakın NDVI değeri gösterir. NDVI hesaplamalarının yapılması için, Python programlama dili ile yazılan program kullanılmıştır. Sayısallaştırılan parsel dosyası, her uydu görüntüsü için, aynı harita sınırları (mapextent) değerine sahip olacak şekilde raster dosyaya dönüştürülmüştür. Hesaplanan NDVI değerleri ile raster parsel haritası çakıştırılarak her parseli oluşturan piksellerin koordinatları ve NDVI değerleri bir dosyaya aktarılmıştır. Değerlendirme ve analizler, oluşturulan bu dosyadaki veriler üzerinden yapılmıştır. Ancak, her parseli oluşturan boyutlarında çok sayıda piksel bulunduğundan, değerlendirmede kolaylık sağlaması açısından, her parseldeki NDVI değerlerinin hesaplanabilmesi için belirli parseller üzerinde GPS ile koordinat noktaları alınmıştır (Gönenç 2019).

Son zamanlarda, NDVI zaman serileri, sınıflandırma doğruluğunu iyileştirmek için fenolojik parametreleri çıkarmak için kullanılmaktadır. Bu fenolojik parametreler bu çalışmada zamansal özellikler olarak kullanılmıştır. Daha spesifik olarak, birkaç


farklı lojistik eğrinin karşılaştırılmasına ve analizine dayalı olarak, NDVI zaman serisi Eşitlik (3.2) ve Eşitlik (3.3) modellendi ve koordinatlara karşılık gelen piksel değerleri hesaplandı.

$$NDVI(t) = a + (b/\gamma)^{(1+\alpha(t))-(\gamma+1)/\gamma} \alpha(t)^{(\gamma+1)(\gamma+1)/\gamma} \quad (3.2)$$

$$\alpha = \exp[(t + d \cdot \ln(\gamma) - c)/d] \quad (3.3)$$

3.5.GPS Verilerinin NDVI Görüntüsüne İşlenmesi


Pilot tarım alanının seçilmesinde Batman Tarım Müdürlüğü'nün denetimi altında bulunan Batman Merkeze bağlı Bıçakçı Köyü sınırında 4 km² alanı kaplayan mercimek ve buğday tarım ürünlerinin ekili olduğu tarım arazisinin çalışma için seçilmiştir. Seçilen pilot tarım alanı sınırları içerisinde alınan 96 farklı noktaya ait GPS verileri bu çalışmada kullanılmıştır. Arazide ekili alanlarda bu koordinat noktalarına karşılık gelen tarım ürünü yerinde tespit edilerek, koordinatlara karşılık gelen ürün çeşidi tespit edilip alınan veriler 'excel çalışma sayfası' ortamına aktarılmıştır. Excel dosyasının uzantısı çalışma sayfası formatından 'virgülle ayrılmış değerler' dosyasına çevrilmiştir. Bu GPS verileri QGIS 3.10.2 coğrafi bilgi sistemi programında 'sınırlandırılmış metin katmanı' ekle sekmesi kullanılarak okutulmuştur. Bunun sonucunda da Şekil 3.9'daki görüntü elde edilmiştir.



Şekil 3.9. QGIS ile seçilen 96 farklı GPS verisinin konum bilgilerine göre dağılımı

Daha önce excell çalışma dosyasıyla kaydettiğimiz koordinat noktalarını, Google Satellite altlık haritasında bulunmasının sonrasında raster-coğrafi sekmesinden referanslama-raster açılış işlem adımları takip edilerek görüntü referanslama yapılması

için ara yüze çağırılmıştır. Koordinat sistemi olarak WGS 84 PseudoMercator EPSG 3857 Google koordinat sistemi seçilmiştir ve görüntünün ekrana gelmesi sağlanmıştır. Coğrafi referanslama aracında noktalar eklenilen görüntünün üzerine belirgin, bulunabilecek köşe noktaları olabilecek yerlere nokta işaretlenmiştir. Nokta ekleyince harita koordinatlarını gir kısmı karşımıza gelmiştir. Noktaların referanslanması için harita kanvası seçilmiştir. Daha sonra karşımıza QGIS'e eklenen Google Earth görüntüsü gelmiştir. Daha önce kaydettiğimiz Google Earth görüntüsü üzerinde eklediğimiz noktanın aynısını Google Earth görüntüsü üzerine eklenmiştir. Bu işlemi yaptıktan sonra noktamızın koordinatları harita kanvasından alınmıştır. Bunun sonucunda da Şekil 3.10'daki görüntü elde edilmiştir.



Şekil 3.10. Pilot tarım alanında bulunan 96 farklı GPS verisinin konum bilgilerine göre dağılımı

3.6. Makine Öğrenme Teknikleri

Makine öğrenme teknikleri, karmaşık ve değişik özelliklerden oluşan verileri, belirli yaklaşımlar doğrultusunda ele alarak çeşitli niteliklerini hesaplamakta ve bu verilere ait örüntüyü oluşturmak için kullanılmaktadır (Flach, 2012).

Bu nedenle, örüntüleri iyi temsil edecek özellikler oluşturulup bunların daha küçük boyuttaki haritalandırılmaları sağlanmalıdır. Bu çalışmada, çeşitli ön işlemlerden geçirilerek elde edilen Landsat-8 NDVI indeks verilerinden tarımsal ürünlere ait özellik vektörleri oluşturulmuş ve makine öğrenme yöntemlerinden faydalanılarak bu ürünlerin sınıflandırılması sağlanmıştır. Makine öğrenme yöntemleri olarak da; Destek Vektör Makineleri (DVM), En Yakın Komşuluk (K-NN) ve Naive Bayes (NB) sınıflandırma

algoritmaları kullanılmıştır. Bütün deneyler MATLAB yazılımı kullanılarak gerçekleştirilmiştir.

3.6.1. Destek Vektör Makineleri (DVM)

Destek Vektör Makineleri (DVM), bilgisayar ve istatistik alanları içinde yer alan denetimli öğrenme tekniklerinden biri olup veri analizi, örüntü tanıma, regresyon analizi ve sınıflandırma için tercih edilmektedir. DVM, doğrusal verilerin sınıflandırılması aşamasında ilk olarak iki sınıflı olarak ortaya çıkmıştır. Daha sonra, lineer olmayan çoklu sınıflara ait verilerin sınıflandırılması için geliştirilmiştir (Eray 2008).

DVM algoritmasında, verilerin lineer olarak ayrılabilmesi ya da ayrılamaması şeklinde iki farklı olasılık karşımıza çıkmaktadır. Lineer olarak ayrılabilen verilerin sınıflandırılmasında, margin (maksimum sınır) değerinin hesaplanması basittir. Fakat günlük yaşantımızda karşılaştığımız problemlere ait veriler lineer olarak ayrılacakları bir düzleme aktarılması gerekmektedir (Eray 2008).

DVM yöntemi, doğrusal ve doğrusal olmayan DVM olmak üzere iki ana başlıkta incelenmiştir.


3.6.1.1. Doğrusal Destek Vektör Makinesi Sınıflandırıcıları

Doğrusal DVM, verilerin doğrusal olarak ayrılabilmesi ve ayrılamaması olarak iki şekilde ele alınmıştır.

$X = \{x_i, y_i\}$ eğitim veri kümesinin ($i = 1, 2, \dots, n$) n tane elemandan oluştuğunu varsayalım. Burada, $y_i \in \{-1, 1\}$ etiket değerlerini, x ise öznitelik vektörünü ifade etmektedir. Hiperdüzlem, doğrusal olarak ayrılabilme durumunda olan verileri bu değerler sayesinde ayırabilir. DVM' nin amacı, her iki örnek veri kümesine, bu hiperdüzlemle eşit mesafe oluşturmaktır. Lineer ayrılabilme koşulu için ayırıcı hiperdüzlem denklem (3.4)'de gösterilmiştir.

$$f(\Phi) = \alpha^T w + b = \sum_{i=1}^n \alpha_i w_i + b \quad (3.4)$$

Burada w ağırlık vektörünü, b değeri de bir sapma değerini sembol etmektedir. Doğrusal ayrılabilme durumu için hiperdüzlem Şekil 3.11' de gösterilmiştir.



Şekil 3.12. Linear ayrılabilir durumda optimal hiperdüzlem

3.6.1.2. Doğrusal Olarak Ayrılama Durumu

Verilere ait örneklerin lineer olarak ayrılamadığı koşullarda, doğrusal olmayan sınıflandırıcıların kullanımı, DVM sınıflandırıcısının yüksek hata yapmasına neden olmaktadır. Bu problemin ortadan kaldırılması için, Eşitlik (3.9) ve (3.10) belli bir hata miktarı göz önünde bulundurularak yeniden düzenlenmelidir. Hata miktarı ψ ve $i = 1, 2, \dots, m$ olarak alınırsa; Eşitlik (3.9) ve (3.10) koşulları elde edilir.

$$w^T x_i + b \geq 1 - \psi_i, \quad y_i = +1, \quad \psi_i \geq 0 \quad (3.9)$$


$$w^T x_i + b \geq -1 + \psi_i, \quad y_i = -1, \quad \psi_i \geq 0 \quad (3.10)$$

Burada, $i = 1, 2, \dots, m$ ve ψ pozitif zayıflık parametreleri olarak isimlendirilmektedir. Bu eşitlikler yeniden düzenlenecek olursa;

$$f(w, \psi) = S \sum_{i=1}^m \psi_i + \frac{1}{2} \|w\|^2, \quad i = 1, 2, \dots, m \quad \psi_i \geq 0 \quad (3.11)$$

$$Q_i = (w^T x_i + b)y_i \geq 1 - \psi_i, \quad i = 1, 2, \dots, m \quad \psi_i \geq 0 \quad (3.12)$$

Minimizasyon (3.11) ve Kısıtlama (3.12) denklemleri elde edilmektedir. Lineer olarak ayrılmama durumunda optimal ayırıcı hiperdüzlem Şekil 3.13.'de gösterilmiştir.



Şekil 3.13. Lineer olarak ayrılmama durumunda optimal hiperdüzlem

Lineer olarak verilerin ayrılmaması durumunda sistemin ezberlemesini engellemek için sistemde bir S üst sınır parametresi tanımlanmalıdır. Bu parametre, hatalar için önleyici bir faktör, margin (mesafe) için de düzenleyici bir faktör görevini almaktadır. Dahası, S üst sınır parametresi Lagrange çarpanlarının alabileceği en yüksek değeri gösterip bu çarpanların $0 \leq \delta_i \leq S$ değer aralığında kalmasını sağlar. Lagrange fonksiyonu yeniden düzenlenerek problem çözümü için aşağıdaki gibi temsil edilebilmektedir.

$$L_{\text{primal}} = S \sum_{i=1}^m \psi_i + \frac{1}{2} \|w\|^2 - \sum_{i=1}^m \delta_i ((x_i w + b)y_i - 1 + \psi_i) - \sum_{i=1}^m \delta_i \psi_i \quad (3.13)$$

Denklem (3.13)'de, ψ i hata teriminin pozitif olmasını sağlar ve δ_i Lagrange parametrelerini ifade etmektedir. Bu denklemdeki Lagrange fonksiyonunun çözümünde optimizasyon problemi, Karush-Kuhn-Tucker (KKT) koşulları yardımıyla dual hale dönüştürülmektedir. Elde edilen dual problem eşitliği aşağıdaki gibidir.

$$L_{\text{dual}} = \sum_{i=1}^m \delta_i - \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^m \delta_i \delta_j y_i y_j x_i^T x_j \quad (3.14)$$

$$\sum_{i=1}^m y_i \delta_i = 0, \quad 0 \leq \delta_i \leq S, \quad i = 1, 2, \dots, m \quad (3.15)$$

Burada, Eşitlik (3.14) ve (3.15) sırasıyla maksimizasyon ve kısıtlama durumlarını belirtmektedir. Ayrıca, $0 \leq \delta_i \leq S$ aralığındaki Lagrange çarpanlarına denk gelen x_i ise Destek Vektörleri olarak isimlendirilmektedir.

3.6.2. K-En Yakın Komşu (K-NN) Algoritması

K-NN Algoritması, uzaklık hesaplaması temel alınarak geliştirilen bir makine öğrenme yöntemidir. Bu yöntemde sırasıyla aşağıdaki adımlar uygulanmaktadır (Acar, 2017).

- Sınıf değeri hesaplanmak istenen örnek verinin, veri kümesinde bulunan tüm örnekler verilere göre uzaklığı hesaplanır.
- Bu uzaklıklar daha sonra büyükten küçüğe doğru sıralanır.
- En küçük K uzaklık değerine sahip gözlemler alınır.
- K kadar gözlemin içinde çoğunluk oylaması ile en çok tekrar edilen sınıf, örnek verinin sınıf değeri olarak kabul edilir (Bridge, 2013).

Sınıflandırmanın son aşamasında sınıf değerinin bulunmasında, en sık tekrar edilen sınıf değerinin bulunması yerine, ağırlıklı oylama yaklaşımı da tercih edilebilmektedir. Ağırlık olarak, uzaklıkların tersi veya tersinin karesi kullanılabilir. Sınıf bazında hesaplanan bu ağırlıklar daha sonra toplanmakta ve en fazla ağırlığa sahip çıktılar, sınıf değeri olarak atanmaktadır. Ayrıca, gözlemler arasındaki uzaklığın hesaplanması için en yaygın tercih edilen uzaklık ölçüsü Öklid Uzaklığı olup bu parametre Eşitlik (3.16)' da verilmiştir (Bridge, 2013).

$$d(x, y) = \sqrt{\sum_{j=1}^N (x_j - y_j)^2} \quad (3.16)$$

K-NN algoritmasında öğrenilen fonksiyon reel ve ayrık değerli olabilmektedir. Ayrık değerli fonksiyonlarda, x_j sınıflandırılmak istenen örnek veri ve y_j ise öğrenme noktaları olarak isimlendirilsin. Bu durumda, eğer $k=2$ olarak seçilirse “2-NN” (En yakın 2 komşu), örnek veri x_j için $f(y_j)$ hesaplanır ve $f(x_j)$ 'ye değer ataması yapılır (Acar, 2017).

3.6.3. Naive Bayes (NB) Yöntemi

Naive Bayes (NB) algoritması, Bayes teoreminden esinlenilerek ortaya atılmış en basit makine öğrenme algoritmalarından biri olup sınıflandırma amaçlı birçok alanda

kolaylıkla uygulanabilmektedir. Bu algoritmayla, bir örnek veriye ait hedef niteliğinin sınıfını bulma olasılıkları sağlanabilmektedir.

$$P(h/X) = \frac{P(X/h)P(h)}{P(X)} \quad (3.17)$$

$$f(x) = \begin{cases} -x, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (3.18)$$

Denklem (3.17)'de, X öznitelik vektörünü, h ise bir öznitelik vektörünün T gibi bir sınıfa ait olma olasılığını temsil etmektedir. Ayrıca, P(h/X) ardıl olasılığı ifade etmektedir.

Naive Bayes sınıflandırıcısına ait algoritma aşağıdaki adımlar ile gerçekleştirilmektedir.

- Eşitlik (3.18) kullanılarak veri kümesi içerisindeki her x'e ait sınıf etiketinin belli olduğu varsayılın. X, m tane öznitelikten oluşan bir vektör olup $X = (x_1, x_2, \dots, x_m)$ şeklinde ifade edilmektedir.

- Daha sonra, $C_1, C_2, \dots, C_n$ ile ifade edilen n tane sınıfın olduğu varsayılın. Naive Bayes algoritması, bir X vektörünün C_i sınıfına ait olup olmadığını bulmak için, tüm sınıflar içerisinde maksimum $P(C_i / X)$ ardıl olasılığına sahip değeri bulmaya çalışır. Bu durum Bayes teoremi ile Eşitlik (3.19) kullanılarak gösterilmiştir.

$$P(C_i/X) = \frac{P(X/C_i)P(C_i)}{P(X)} \quad (3.19)$$

- $P(X)$ değeri bütün sınıflar için aynı olduğundan, yalnızca $P(X/C_i)P(C_i)$ ifadesi en yüksek yapılmalıdır.

- $P(C_i)$ terimi, C_i sınıfındaki eleman sayısının, tüm eleman sayısına oranı olarak tanımlanmaktadır.

- $P(X/C_i)$ terimi ise, X'in n tane değerden oluşan bir öznitelik vektörü olduğu kabul edildiğinde, Eşitlik (3.20) ile ifade edilmektedir.

$$P(H/C_i) = \prod_{k=1}^n P(X_k/C_i) \quad (3.20)$$

- Sonuç olarak, NB sınıflandırıcısı maksimum $P(X/C_i)P(C_i)$ değerine sahip olan C_i sınıfını, X vektörünün sınıfı olarak atamaktadır (Meena, 2020).

4. ARAŞTIRMA BULGULARI VE TARTIŞMA

Bu aşamada, belirli önışlemlerden geçirilmiş Landsat-8 uydu görüntülerine, QGIS programı yardımıyla örnek noktalara ait koordinatlar aktarılmış ve bu noktalara ait NDVI bitki örtüsü indeksleri hesaplanmıştır. Daha sonra, makine öğrenme yöntemleri kullanılarak tarımsal ürünlerin sınıflandırılması sağlanmıştır.

Yersel veri seti oluşturma sürecinde, Batman İl Müdürlüğü çalışanlarının yardımıyla pilot tarımsal alanlardan GPS ile belirlenen örnek noktaların koordinatları ve bu noktalar üzerinde ekili bulunan tarımsal ürününün (mercimek ve buğday) çeşidi excell dosyası formatında oluşturulmuştur.

Pilot alan üzerindeki örnek noktalara ait NDVI değerleri, 6 Mayıs 2018 ve 30 Ağustos 2018 tarihli Landsat-8 uydu görüntülerine ait 4.Bant (kırmızı) ve 5.Bant (yakın kızılötesi) yardımıyla eşitlik (3.1) ve QGIS programı kullanılarak hesaplanmıştır.

Çizelge 4.1. NDVI Değer Tablosu ve Ürün Bilgisi

GPS NO	X (Enlem)	Y (Boylam)	ÜRÜN ADI	NDVI (06.05.2018)	NDVI (30.08.2018)
1	691194.02	4200949.77	MERCIMEK	0.204495	0.102855
2	691402.27	4200965.2	MERCIMEK	0.210561	0.088309
3	691583.53	4200965.2	MERCIMEK	0.240142	0.107735
4	692027.02	4200965.2	MERCIMEK	0.200505	0.112359
5	692239.12	4200965.2	BUGDAY	0.209054	0.099366
6	692474.37	4200957.49	BUGDAY	0.226434	0.088026
7	692682.62	4200957.49	MERCIMEK	0.222428	0.115787
8	692867.73	4200957.49	BUGDAY	0.213874	0.083640
9	693052.84	4200957.49	BUGDAY	0.154182	0.116765
10	691197.11	4200762.35	BUGDAY	0.224248	0.109516
11	691405.36	4200770.06	BUGDAY	0.208729	0.099052
12	691602.04	4200785.49	BUGDAY	0.233929	0.065960
13	691794.86	4200808.63	BUGDAY	0.261311	0.085742
14	692026.25	4200820.2	MERCIMEK	0.144681	0.086115

15	692253.78	4200824.05	BUGDAY	0.190903	0.106231
16	692465.88	4200816.34	BUGDAY	0.198473	0.099113
17	692685.7	4200812.48	MERCIMEK	0.181556	0.114994
18	692878.53	4200824.05	BUGDAY	0.150324	0.120914
19	693059.78	4200804.77	BUGDAY	0.194672	0.095088
20	691197.11	4200611.95	BUGDAY	0.357950	0.098361
21	691409.21	4200611.95	BUGDAY	0.251347	0.115274
22	691609.75	4200615.8	BUGDAY	0.195278	0.066159
23	691806.43	4200623.52	BUGDAY	0.222246	0.064816
24	692041.67	4200638.94	BUGDAY	0.263296	0.088723
25	692261.49	4200646.66	MERCIMEK	0.148260	0.116796
26	692485.17	4200646.66	MERCIMEK	0.148257	0.113255
27	692693.42	4200654.37	MERCIMEK	0.172393	0.098675
28	692890.1	4200658.23	MERCIMEK	0.151227	0.121502
29	693079.06	4200658.23	BUGDAY	0.199714	0.123955
30	691197.11	4200465.4	BUGDAY	0.344912	0.096435
31	691405.36	4200476.97	BUGDAY	0.220723	0.105989
32	691621.32	4200473.12	BUGDAY	0.178557	0.08588
33	691814.14	4200480.83	BUGDAY	0.226471	0.064283
34	692041.67	4200473.12	BUGDAY	0.221750	0.102185
35	692261.49	4200496.25	MERCIMEK	0.150546	0.113939
36	692481.31	4200500.11	MERCIMEK	0.140443	0.132539
37	692693.42	4200492.4	MERCIMEK	0.134558	0.112212
38	692917.09	4200500.11	MERCIMEK	0.133595	0.085336
39	693117.63	4200496.25	MERCIMEK	0.133321	0.08476
40	691189.39	4200318.86	MERCIMEK	0.165372	0.103460
41	691617.46	4200326.57	BUGDAY	0.170060	0.067175
42	691818.02	4200330.43	BUGDAY	0.176115	0.100355
43	692049.39	4200345.85	MERCIMEK	0.210202	0.116242
44	692265.35	4200353.57	MERCIMEK	0.133482	0.141213
45	692485.17	4200353.57	MERCIMEK	0.180962	0.115531
46	692693.42	4200353.57	MERCIMEK	0.205431	0.121602

47	692928.66	4200365.13	MERCIMEK	0.153556	0.118318
48	693129.2	4200361.28	MERCIMEK	0.149033	0.085252
49	691189.39	4200183.88	MERCIMEK	0.161833	0.111346
50	691424.64	4200183.88	MERCIMEK	0.177279	0.070936
51	691617.46	4200191.59	BUGDAY	0.228012	0.121295
52	691821.85	4200199.31	BUGDAY	0.189038	0.071259
53	692060.96	4200214.73	MERCIMEK	0.149774	0.106977
54	692280.77	4200222.45	MERCIMEK	0.194937	0.110497
55	692500.59	4200222.45	MERCIMEK	0.133674	0.107529
56	692693.42	4200222.45	MERCIMEK	0.145988	0.112285
57	692928.66	4200218.59	MERCIMEK	0.133903	0.112769
58	693133.05	4200226.3	BUGDAY	0.188825	0.110126
59	691193.25	4200033.48	MERCIMEK	0.151563	0.100983
60	691413.07	4200060.47	BUGDAY	0.245303	0.091754
61	691621.32	4200041.19	BUGDAY	0.233213	0.113316
62	691841.14	4200052.76	BUGDAY	0.223905	0.086977
63	692076.38	4200068.19	BUGDAY	0.256878	0.083069
64	692315.48	4200075.9	BUGDAY	0.280447	0.078822
65	692523.73	4200087.47	BUGDAY	0.182410	0.114828
66	692697.27	4200087.47	BUGDAY	0.169738	0.065429
67	693133.05	4200075.9	BUGDAY	0.212699	0.109768
68	691197.11	4199906.22	MERCIMEK	0.153191	0.119453
69	691389.93	4199913.93	BUGDAY	0.179347	0.106622
70	691598.18	4199925.5	BUGDAY	0.216957	0.106834
71	691848.85	4199940.92	BUGDAY	0.282328	0.094014
72	692072.52	4199933.21	BUGDAY	0.222659	0.106711
73	692330.91	4199960.21	BUGDAY	0.220283	0.087347
74	692531.44	4199964.06	BUGDAY	0.220602	0.111735
75	692704.98	4199967.92	BUGDAY	0.208192	0.074360
76	692947.94	4199960.21	BUGDAY	0.198091	0.136480
77	693133.05	4199967.92	BUGDAY	0.197237	0.103978
78	691208.68	4199778.95	MERCIMEK	0.179706	0.096665


79	691401.5	4199786.67	MERCIMEK	0.174482	0.090578
80	691613.61	4199794.38	MERCIMEK	0.178605	0.106889
81	691856.56	4199790.52	BUGDAY	0.191049	0.103277
82	692072.52	4199794.38	BUGDAY	0.154682	0.088345
83	692346.33	4199805.95	BUGDAY	0.210059	0.083582
84	692535.3	4199813.66	MERCIMEK	0.149261	0.083151
85	692716.55	4199817.52	BUGDAY	0.240147	0.090852
86	693136.91	4199802.09	MERCIMEK	0.131265	0.153812
87	691204.82	4199620.84	MERCIMEK	0.182009	0.105191
88	691393.79	4199628.55	BUGDAY	0.224429	0.092581
89	691590.47	4199636.26	MERCIMEK	0.206260	0.086549
90	691860.42	4199647.83	BUGDAY	0.209829	0.086911
91	692060.96	4199643.98	BUGDAY	0.176548	0.096903
92	692330.91	4199663.26	BUGDAY	0.192492	0.085558
93	692558.44	4199655.55	BUGDAY	0.165177	0.100222
94	692758.98	4199667.11	BUGDAY	0.104607	0.097965
95	692967.22	4199655.55	BUGDAY	0.242708	0.142394
96	693140.77	4199643.98	MERCIMEK	0.129012	0.106589

4.1.NDVI Görüntüsü Elde Edilmesi


Normalize edilmiş farklı bitki örtüsü indeksi (NDVI), bitki büyümesini ve klorofil seviyelerini izlemek için uzaktan algılamada yaygın olarak kullanılmaktadır. Genellikle, NDVI'yi hesaplamak için yakın kızılötesi (NIR) ve kırmızı bantlara ait yansıma indeksler gereklidir. Bitki klorofili kırmızı ışığı emer ve çoğunlukla yakın kızılötesi (NIR) ışığı yansıtır, böylece bitkileri toprak ve su gibi diğer maddelerden ayırır (Rabatel ve ark. 2104). Bu özelliğe dayanarak normalize edilmiş bitki örtüsü indeksi (NDVI), bitki sağlığını izlemek için kırmızı ve NIR yansıması arasındaki oran olarak hesaplanır. 1970'lerden bu yana, NDVI, uydu görüntülerinde bitki örtüsünü ve diğer malzemeleri ayırt etmek için uzaktan algılamada yaygın olarak kullanılmaktadır. NDVI'nın yeşil biyokütle ve mahsul verimi ile önemli korelasyonlara sahip olduğu da kanıtlanmıştır. Genellikle, NDVI bitkilerin doğru kırmızı ve NIR yansımasını yakalayan

bir multispektral kamera (MSC) veya hiperspektral kamera (HSC) tarafından yakalanan görüntülerden elde edilir.(Wung ve ark.-2020)


Bu çalışmada 06.05.2018 tarihli uydu görüntüsünde, NDVI görüntüsünün elde edilmesi için Çizelge 3.2’de belirtilen kırmızı (görünür) ve yakın kızılötesi bantlara (bant 4, bant 5) ait görüntüler Şekil 4.1 ’de gösterilmiştir. Bu görüntüler QGIS programında raster hesaplayıcı sayesinde Eşitlik 3.1 de belirtilen NDVI formülü doğrultusunda hesaplanmıştır. Bu işlemler sonucunda Şekil 4.2’teki NDVI görüntüsü elde edilmiştir. Elde edilen NDVI görüntüsü daha sonra ‘tek bant yalancı renk katmanı’ şekline çevrilerek Şekil 4.3’da gösterilmiştir. Ayrıca görüntünün GPS verisi işlenmiş hali de Şekil 4.4’de gösterilmiştir.



Şekil 4.1. Landsat-8 uydusu 06.05.2018 tarihli Pilot tarım alanına ait (a) Bant 4 (görünür) ve (b) Bant 5 (yakın kızılötesi) görüntüsü



Şekil 4.2 06.05.2018 tarihli Pilot tarım alanına ait NDVI görüntüsü




Şekil 4.3. 06.05.2018 tarihli Pilot tarım alanına ait tek bant yalancı renk katmanı şeklindeki Viridis bant NDVI görüntüsü



Şekil 4.4. 06.05.2018 tarihli Pilot tarım alanına ait tek bant yalancı renk katmanı şeklindeki Viridis bant NDVI görüntüsü (GPS verisi işlenmiş hali)

30.08.2018 tarihli uydu görüntüsünde, NDVI görüntüsünün elde edilmesi için Çizelge 3.2’de belirtilen kırmızı (görünür) ve yakın kızılötesi bantlara (bant 4, bant 5)


ait görüntüler Şekil 4.5 'de gösterilmiştir. Bu görüntüler QGIS programında raster hesaplayıcı sayesinde Eşitlik 3.1 de belirtilen NDVI formülü doğrultusunda hesaplanmıştır. Bu işlemler sonucunda Şekil 4.6'daki NDVI görüntüsü elde edilmiştir. Elde edilen NDVI görüntüsü daha sonra 'tek bant yalancı renk katmanı' şekline çevrilerek Şekil 4.7'de gösterilmiştir. Ayrıca görüntünün GPS verisi işlenmiş hali de Şekil 4.8'de gösterilmiştir.



(a) Bant 4

(b) Bant 5


Şekil 4.5. Landsat-8 uydusu 30.08.2018 tarihli Pilot tarım alanına ait (a) Bant 4 (görünür) ve (b) Bant 5 (yakın kızılötesi) görüntüsü



Şekil 4.6. 30.08.2018 tarihli Pilot tarım alanına ait NDVI görüntüsü



Şekil 4.7. 30.08.2018 tarihli Pilot tarım alanına ait tek bant yalancı renk katmanı şeklindeki RdGy bant NDVI görüntüsü



Şekil 4.8. 30.08.2018 tarihli Pilot tarım alanına ait tek bant yalancı renk katmanı şeklindeki RdGy bant NDVI görüntüsü (GPS verisi işlenmiş hali)

4.2. Makine Öğrenme Teknikleri Yardımıyla NDVI Değerlerinden Ürün Tespitine ait Bulgular

Bu kısımda, GPS noktalarına karşılık gelen NDVI değerleri piksel tabanlı olarak hesaplanmış ve makine öğrenmesi için her bir örnek noktanın öznitelik vektörleri farklı zamanlara ait NDVI değerleri kullanılarak oluşturulmuştur. NDVI değerlerinden elde edilen öznitelik vektörleri daha sonra sınıflandırıcıların eğitim ve test aşamasında kullanılmıştır.

Sınıflandırma aşamasında, makine öğrenme yöntemlerinden DVM, KNN ve NB kullanılmıştır. Eğitim ve test aşamasında birini dışarda bırak (leave-one-out) çapraz doğrulama yöntemi uygulanmıştır. Önerilen sınıflandırma sistemlerinin performans hesabı için, Eşitlik (4.1), (4.2), (4.3), (4.4), (4.5) ve (4.6) 'da ki istatistiksel parametreler kullanılmıştır. Ayrıca, Çizelge 4.2'de görüldüğü gibi karışıklık matrisi (Confusion Matrix) de performans hesabı için kullanılmıştır.

Çizelge 4.2. Karışıklık Matrisi Tablosu

		Tahminlenen (Predicted)	
Gerçekleşen (Actual)	Gerçek Pozitif (TP)	Yanlış Pozitif (FP)	
	Doğru Negatif (TN)	Yanlış Negatif (FN)	

1. Gerçek Pozitif (TP)
2. Doğru Negatif (TN)
3. Yanlış Pozitif (FP)
4. Yanlış Negatif (FN)

Doğruluk (Accuracy) : Doğru tahmin edilen örneklerin toplam tahmin edilen örneklere oranıdır.

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \quad (4.1)$$

Hassasiyet (Sensitivity) : Doğru tahmin edilen pozitif örneklerin gerçek sınıftaki tüm örneklerle oranıdır.

$$\text{Hassasiyet} = \frac{TP}{TP + FN} \quad (4.2)$$

Özgüllük (Specificity) : Doğru tahmin edilen negatif örneklerin toplam tahmin edilen pozitif örneklerle oranıdır.

$$\text{Duyarlılık} = \frac{TN}{TN + FP} \quad (4.3)$$

Kesinlik (Precision) : Doğru tahmin edilen pozitif örneklerin toplam tahmin edilen pozitif örneklerle oranıdır.

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (4.4)$$

Duyarlılık (Recall): Doğru tahmin edilen pozitif örneklerin gerçek sınıftaki tüm örneklerle oranıdır.

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (4.5)$$


F1-Skor: Kesinlik ve Duyarlılığın ağırlıklı ortalamasıdır. Bu nedenle, f1-score hem yanlış pozitifleri hem de yanlış negatifleri dikkate almaktadır.

$$F1 \text{ Skoru} = 2 \frac{\text{Duyarlılık} * \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}} \quad (4.6)$$

4.2.1. NDVI ve DVM Yaklaşımından Hesaplanan Performans Metrikleri

6 Mayıs 2018, 30 Ağustos 2018 ve bu iki tarihin birlikte kullanılmasıyla oluşturulan NDVI tabanlı veri setleri kullanılarak tarımsal ürünlerin tespiti için DVM yöntemi kullanılmış ve sınıflandırma yöntemine ait karışıklık matrisi tabloları sırasıyla Çizelge 4.4, Çizelge 4.6, ve Çizelge 4.8’de verilmiştir. Dahası, her üç gruba ait performans metrikleri sırasıyla Çizelge 4.3, Çizelge 4.5, ve Çizelge 4.7’de sunulmuştur.


Çizelge 4.3. 06.05.2018 tarihli NDVI parametreleri ve DVM yaklaşımına ait Karışıklık Matrisi Tablosu



Çizelge. 4.4 06.05.2018 tarihli NDVI parametreleri ve DVM yaklaşımına ait Performans Metrikleri

Performans Metriği	Sonuç (%)
<i>Hassasiyet (Sensitivity)</i>	90.1639
<i>Özgüllük (Specificity)</i>	71.4286
<i>Kesinlik (Precision)</i>	84.6154
<i>Duyarlılık (Recall)</i>	90.1639
<i>F1 Skoru</i>	87.3016
<i>Doğruluk (Accuracy)</i>	83.3333


Çizelge 4.5. 30.08.2018 tarihli NDVI parametreleri ve DVM yaklaşıma ait Karışıklık Matrisi Tablosu



Çizelge 4.6. 30.08.2018 tarihli NDVI parametreleri ve DVM yaklaşıma ait Performans Metrikleri

Performans Metriği	Sonuç (%)
<i>Hassasiyet (Sensitivity)</i>	90.1639
<i>Özgüllük (Specificity)</i>	0
<i>Kesinlik (Precision)</i>	61.1111
<i>Duyarlılık (Recall)</i>	90.1639
<i>F1 Skoru</i>	72.8477
<i>Doğruluk (Accuracy)</i>	57.2917

Çizelge 4.7. 06.05.2018 ile 30.08.2018 NDVI parametreleri ve DVM yaklaşımına Karışıklık Matrisi Tablosu



Çizelge 4.8. 06.05.2018 ile 30.08.2018 NDVI parametreleri ve DVM yaklaşımına ait Performans Metrikleri

Performans Metriği	Sonuç (%)
<i>Hassasiyet (Sensitivity)</i>	85.7143
<i>Özgüllük (Specificity)</i>	75.0000
<i>Kesinlik (Precision)</i>	82.7586
<i>Duyarlılık (Recall)</i>	85.7143
<i>F1 Skoru</i>	84.2105
<i>Doğruluk (Accuracy)</i>	81.2500

DVM yöntemine ait sonuçlar incelendiğinde, en iyi tespit sonucuna Doğruluk yüzdesi (%83.3), Hassasiyet Yüzdesi (%90.2) ve F1 Skor yüzdesi (%87.3) değerleriyle, 6 Mayıs 2018 tarihli NDVI indeksleri kullanılarak varıldığı gözlemlenmiştir.

4.2.2. NDVI ve NB Yaklaşımından Hesaplanan Performans Metrikleri

6 Mayıs 2018, 30 Ağustos 2018 ve bu iki tarihin birlikte kullanılmasıyla oluşturulan NDVI tabanlı veri setleri kullanılarak tarımsal ürünlerin tespiti için NB yöntemi kullanılmış ve sınıflandırma yöntemine ait karışıklık matrisi tabloları sırasıyla Çizelge 4.10, Çizelge 4.12 ve Çizelge 4.14’de verilmiştir. Ayrıca, her üç gruba ait performans metrikleri sırasıyla Çizelge 4.9, Çizelge 4.11 ve Çizelge 4.13’de sunulmuştur.


Çizelge 4.9. 06.05.2018 tarihli NDVI parametreleri ve NB yaklaşıma ait Karışıklık Matrisi Tablosu

Confusion Matrix		
Output Class	0	1
0	34 35.4%	7 7.3%
1	6 6.3%	49 51.0%
		Target Class
		0
		1
		85.0% 15.0%
		87.5% 12.5%
		86.5% 13.5%

Çizelge 4.10. 06.05.2018 tarihli NDVI parametreleri ve NB yaklaşıma ait Performans Metrikleri

Performans Metriği	Sonuç (%)
<i>Hassasiyet (Sensitivity)</i>	87.5000
<i>Özgüllük (Specificity)</i>	85.0000
<i>Kesinlik (Precision)</i>	89.0909
<i>Duyarlılık (Recall)</i>	87.5000
<i>F1 Skoru</i>	88.2883
<i>Doğruluk (Accuracy)</i>	86.4583


Çizelge 4.11. 30.08.2018 tarihli NDVI parametreleri ve NB yaklaşıma ait Karışıklık Matrisi Tablosu



Çizelge 4.12. 30.08.2018 tarihli NDVI parametreleri ve NB yaklaşıma ait Performans Metrikleri

Performans Metriği	Sonuç (%)
<i>Hassasiyet (Sensitivity)</i>	76.5625
<i>Özgüllük (Specificity)</i>	46.8750
<i>Kesinlik (Precision)</i>	74.2424
<i>Duyarlılık (Recall)</i>	76.5625
<i>F1 Skoru</i>	75.3846
<i>Doğruluk (Accuracy)</i>	66.6667

Çizelge 4.13. 06.05.2018 ile 30.08.2018 NDVI parametreleri ve NB yaklaşıma ait Karışıklık Matrisi Tablosu



Çizelge 4.14. 06.05.2018 ile 30.08.2018 NDVI parametreleri ve NB yaklaşımına ait Performans Metrikleri


Performans Metriği	Sonuç (%)
<i>Hassasiyet (Sensitivity)</i>	82.4561
<i>Özgüllük (Specificity)</i>	82.0513
<i>Kesinlik (Precision)</i>	87.0370
<i>Duyarlılık (Recall)</i>	82.4561
<i>F1 Skoru</i>	84.6847
<i>Doğruluk (Accuracy)</i>	82.2917

NB yaklaşımına ait sonuçlar incelendiğinde ise Doğruluk yüzdesi (% 86.5), Hassasiyet Yüzdesi (% 87.5) ve F1 Skor yüzdesi (% 88.3) değerleriyle ürünün gelişme dönemine ait 6 Mayıs 2018 tarihli görüntü indekslerinin ürün tahmininde daha etkili olduğu sonucuna varılmıştır.

4.2.3. NDVI ve K-NN Yaklaşımından Hesaplanan Performans Metrikleri

6 Mayıs 2018, 30 Ağustos 2018 ve bu iki tarihin birlikte kullanılmasıyla oluşan NDVI indeks değerli veri kümelerinin K-NN yöntemi kullanılarak tarımsal ürünlerin tespitine ait karışıklık matrisi tabloları sırasıyla Çizelge 4.15, Çizelge 4.17 ve Çizelge 4.19’de verilmiştir. Ayrıca, her üç gruba ait performans metrikleri sırasıyla Çizelge 4.16, Çizelge 4.18 ve Çizelge 4.20’de verilmiştir.


Çizelge. 4.15 06.05.2018 tarihli NDVI parametreleri ve k-NN yaklaşıma ait Karışıklık Matrisi Tablosu



Çizelge 4.16. 06.05.2018 tarihli NDVI parametreleri ve K-NN yaklaşıma ait Performans Metrikleri

Performans Metriği	Sonuç (%)
<i>Hassasiyet (Sensitivity)</i>	88.6792
<i>Özgüllük (Specificity)</i>	72.0930
<i>Kesinlik (Precision)</i>	79.6610
<i>Duyarlılık (Recall)</i>	88.6792
<i>F1 Skoru</i>	83.9286
<i>Doğruluk (Accuracy)</i>	81.2500


Çizelge 4.17. 30.08.2018 tarihli NDVI parametreleri ve K-NN yaklaşıma ait Karışıklık Matrisi Tablosu



Çizelge 4.18. 30.08.2018 tarihli NDVI parametreleri ve K-NN yaklaşıma ait Performans Metrikleri

Performans Metriği	Sonuç (%)
<i>Hassasiyet (Sensitivity)</i>	65.4545
<i>Özgüllük (Specificity)</i>	48.7805
<i>Kesinlik (Precision)</i>	63.1579
<i>Duyarlılık (Recall)</i>	65.4545
<i>F1 Skoru</i>	64.2857
<i>Doğruluk (Accuracy)</i>	58.3333

Çizelge 4.19. 06.05.2018 ile 30.08.2018 NDVI parametreleri ve K-NN yaklaşıma ait Karışıklık Matrisi Tablosu



Çizelge 4.20. 06.05.2018 ile 30.08.2018 NDVI parametreleri ve K-NN yaklaşıma ait Performans Metrikleri

Performans Metriği	Sonuç (%)
Hassasiyet (<i>Sensitivity</i>)	78.9474
Özgüllük (<i>Specificity</i>)	64.1026
Kesinlik (<i>Precision</i>)	76.2712
Duyarlılık (<i>Recall</i>)	78.9474
F1 Skoru	77.5862
Doğruluk (<i>Accuracy</i>)	72.9167

Çalışmanın bu bölümünde makine öğrenmesi K-NN yöntemi, sınıflandırıcı parametrelerden k için 1-9 arası değerler ile test edilmiştir. En iyi sonuca k=7 değeri için test edildiğinde ulaşılmıştır.

Son olarak, K-NN yöntemine ait sonuçlar ele alındığında, Doğruluk yüzdesi (% 81.3), Hassasiyet Yüzdesi (% 88.7) ve F1 Skor yüzdesi (% 83.9) değerleriyle ürünün gelişme dönemine ait 6 Mayıs 2018 tarihli görüntü indekslerinin ürün tahmininde daha etkili olduğu sonucuna varılmıştır.

4.3. Bulguların Değerlendirilmesi

Bu çalışma da üç grubun veri setlerine ait tüm kombinasyonlar incelendiğinde, makine öğrenmesi yöntemlerinden, DVM, NB ve K-NN, en iyi tahmin modeli için veri seti performans metrikleri karşılaştırılmıştır.

Çizelge 4.21. Çalışmada kullanılan makine öğrenmesi tekniklerinin karşılaştırılması

	DVM		NB		k-NN	
Görüntü Tarihi	06.05.2018	30.08.2018	06.05.2018	30.08.2018	06.05.2018	30.08.2018
<i>Hassasiyet (Sensitivity)</i>	90.1639	90.1639	87.5	76.5625	88.6792	65.4545
<i>Özgüllük (Specificity)</i>	71.4286	0	85	46.875	72.093	48.7805
<i>Kesinlik (Precision)</i>	84.6154	61.1111	89.0909	74.2424	79.661	63.1579
<i>Duyarlılık (Recall)</i>	90.1639	90.1639	87.5	76.5625	88.6792	65.4545
<i>F1 Skoru</i>	87.3016	72.8477	88.2883	75.3846	83.9286	64.2857
<i>Doğruluk (Accuracy)</i>	83.3333	57.2917	86.4583	66.6667	81.25	58.3333

Çizelge 4.21 incelendiğinde, doğruluk yüzdesi (% 86.5), Hassasiyet Yüzdesi (% 87.5) ve F1 Skor yüzdesi (% 88.3) değerleri ile en yüksek performans değeri NB yaklaşımında görülmüştür. Bunun sebebi, NB yaklaşımının NDVI görüntülemesinde daha yüksek F1 Skor yüzdesine sahip olmasıdır.

Bununla birlikte, farklı tarihlere ait oluşturulan görüntü grupları performans metrikleri karşılaştırıldığında, üç grupta gözlemlenen en yüksek değerler 06.05.2018 tarihli grupta görülmüştür. Bunun sebebi, görüntü alınan tarihin, ürünlerin gelişme

dönemini kapsamaması nedeniyle daha yüksek klorofil oranına sahip olması ve NDVI değerlerinin yüksek olmasından kaynaklanmaktadır.

Çizelge 4.22. Makine öğrenmesi yöntemleri ile yapılan çalışmaların karşılaştırma tablosu

Literatür	Yöntem	Doğruluk (%)
Manolya ve ark.	DVM	77.2
Ngugive ve ark.	DT	79.0
Chakher ve ark.	DVM	82.4
Lebrini ve ark.	RF	88.0
Kumar ve ark.	YSA	92.3
Kobayashi ve ark	MSI	93.1
Önerilen çalışma	NB	86.5

Çizelge 4.22'e ait literatür sonuçları ele alındığında, yapılan çalışmamızın diğer çalışmaların çoğundan daha iyi sonuçlar verdiği gözlemlenmiştir.

5. SONUÇLAR VE ÖNERİLER

5.1. Sonuçlar

Uzaktan algılama sistemleri obje ile temas etmeden uydu görüntüleri sayesinde yüzeydeki bitki örtüsü hakkında bilgi edinilmesini sağlamaktadır. Bitki örtüsü ile kaplı tarımsal araziler üzerindeki ürün türünün tahmininde tarım müdürlüğünde kullanılan uygulama için kızılötesi bandında uydu görüntüsü incelenir ve bandın klorofil oranının yoğunluk renk spektrumuna bakılarak ürün tespiti yapılır. Tespiti yapılmayan noktalarda ise yerinde tespit yapılmaktadır.

Bu çalışmada pasif algılama sistemine sahip elektro-optik bazlı çalışan Landsat-8 uydusuna ait görüntüler kullanılmıştır. Bu uydu görüntülerinin incelenmesinde bitki örtüsü indekslerinden yararlanılmıştır. Bitki örtüsü indeksleri, bitki örtüsü yoğunluğunun ve çeşitliliğinin belirlenmesinde önemli bir parametredir. Landsat-8 uydusu içinde multispektral bitki örtüsü indekslerinden olan NDVI hesaplanmıştır. Hesaplanan değerler veri olarak makine öğrenmesinde farklı yaklaşımlardan geçerek ürün tahmini incelemeleri yapılmıştır. Bu inceleme birkaç aşamadan oluşmaktadır.

İlk aşamada pilot tarım arazi alanı belirlenmiş ve hangi ürüne ait veri toplama işlemi gerçekleştirileceğine karar verilmiştir. Seçilen bölgedeki ürünlerin tespiti için 96 adet konum bilgilerini içeren GPS koordinatları alınmıştır. Alınan koordinat noktalarına ait ürün çeşidi bilgisi alınarak veriler oluşturulmuştur.

İkinci aşamada yer gözlemleme uydu platformları ve coğrafi bilgi sistemi yazılımları kullanılarak görüntüler bu programlara işlenmiştir. Landsat-8 uydusuna ait 6 Mayıs 2018 ve 30 Ağustos 2018 tarihli görüntüler çeşitli ön işlemlerden geçirilmiş ve bu görüntüler kullanılmak üzere coğrafi bilgi sistemi programı olan QGIS.3.10.2 yazılımına işlenmiştir. GIS'te yapılan işlemler sonrasında tarihsel sıralama ile oluşturulan gruplara ait NDVI değerleri hesaplanıp her koordinata karşılık gelen değerler listelenerek makine öğrenmesi yaklaşım yöntemlerinde veri olarak kullanılmıştır.

Sonraki aşamada iki farklı tarihe ait 3 farklı grup oluşturulmuştur. Oluşturulan bu gruplara elde edilen veri setleri makine öğrenmesi yöntemlerinden DVM, NB ve k-NN yaklaşımları ayrı ayrı uygulanmıştır. Her uygulamanın sonucunda her bir gruba

ait performans metrikleri ve karışıklık matris tablosu oluşturulmuştur. Performans metriklerinde ise hassasiyet, özgüllük, kesinlik, duyarlılık, F1 Skoru ve doğruluk oranı değerleri hesaplanmıştır.

Sonuç olarak bu çalışmada ortaya konulan bulgular doğrultusunda tahmini yapılacak ürünlerin veri gruplandırmalarının makine öğrenmesi yaklaşımlarıyla ürün tespitindeki doğruluk oranı hesaplanmıştır. Bu gruplar içerisinde en düşük hata oranı 6 Mayıs 2018 tarihli grupta görülmüştür. Makine öğrenmesi yaklaşımlarını karşılaştırılmasında elde edilen sonuçlardan Naive Bayer yönteminin diğer yöntemlere göre daha yüksek doğruluk oranına sahip olduğu görülmüştür. NDVI değerleri kullanılarak yapılan çalışmada ürün tespitinde kullanılan makine öğrenmesi yaklaşımının ve ürünün gelişim safhasının doğruluk oranının hesaplanmasında belirgin bir şekilde etkili olduğu gözlemlenmiştir.

5.2. Öneriler

Bu çalışmanın devamı olarak, farklı uydu görüntülerinden elde edilecek bitki indeks değerleri yardımıyla çeşitli makine öğrenme teknikleri kullanılarak tarımsal ürünlerin tespiti hedeflenmektedir.

Ayrıca, çalışma alanının daha küçük bir parselde daha fazla tarımsal ürün çeşitliliği ile gerçekleştirilmesi durumunda, önerilen sistemin performansının nasıl değişeceğinin araştırılması düşünülmektedir.

KAYNAKLAR

- Acar, E. 2017. Dicle Nehri Havzasında Toprak Nem Ölçümleri İle Sar İmgeleri Arasındaki İlişkiyi Saptama Ve Bu İlişkiye Dayalı Toprak Neminin Tahmini, Doktora Tezi, D.Ü, Fen Bilimleri Enstitüsü, Diyarbakır.
- Alliance, S., 2013. Using SAR-Derived Vegetation Descriptors in a Water Cloud Model to Improve Soil Moisture Retrieval. Canada Centre for Mapping and Earth Observation, Natural Resources Canada, Ottawa, ON K1A 0E4, Canada. Remote Sens. 2013, 10, 1370.
- Anonim, 2013, Canadian Space Agency (CSA). Radarsat-1: Seventeen Years of Technological Success .Erişim Tarihi: 02.10.2020.
- Anonim, 2017. Canadian Space Agency (CSA). Radarsat. Satellite characteristics Erişim: [http://www.asc-csa.gc.ca/eng/satellites/radarsat/radarsat-tableau.asp].
- Anonim, 2018, Canadian Space Agency (CSA). Radarsat-1, Erişim: [http://www.asc-csa.gc.ca/eng/satellites/radarsat1/default.asp]. Erişim Tarihi: 22.10.2020.
- Aydoğdu, M., Mermer, A., Ünal, E., Yıldız, H., Avağ, A., Urla, Ö. ve Ünal, S., 2011. Mera Vegetasyonunun Uydu Görüntüleri (Ndvi) İle İzlenmesi. TUFUAB VI. Teknik Sempozyumu, 23-26 Şubat 2011, Topkapı Palace Otel, Antalya.
- Bridge, J.F., Wardlow, B.D., Tsegaye, T., Hayes, M.J., Reed, B.C., 2013. The vegetation drought response index: a new integrated approach for monitoring drought stress in vegetation, GIScience and Remote Sensing, 45, ss. 1548-1603.
- Chakhar, A., Damián, O., David H.L., Ballesteros, R., Ortega, J. ve Moreno, M., 2020. Landsat-8 ve Sentinel-2 Verilerini Kullanarak Mahsul Sınıflandırması için Çoklu Sınıflandırma Algoritmalarının Doğruluğunu Değerlendirme. Yayın Tarihi: 28 Mayıs 2020.
- Çelik, M.A., Sönmez, M.E., 2013, Kızıltepe İlçesinin Tarımsal Yapısındaki Değişimlerin Modis Ndvi Verileri Kullanılarak İzlenmesi Ve İncelenmesi. Marmara Coğrafya Dergisi Sayı: 27, Ocak - 2013, S. 262-281.
- Çölkesen, İ. ve Kavzoğlu, T. 2011. Uzaktan Algılama Teknolojileri ve Uygulama Alanları. Türkiye’de Sürdürülebilir Arazi Yönetimi Çalıştayı, 26-27 Mayıs, Okan Üniversitesi, İstanbul.
- Delen K. , 2017. Günümüzde Uzaktan Algılama Uygulamalarına Genel Bir Bakış. TMMOB Harita ve Kadastro Mühendisleri Odası 11. Türkiye Harita Bilimsel ve Teknik Kurultayı 2-6 Nisan 2007, Ankara.
- Doğan, H.M., Kılıç, O.M., Yılmaz, D.S. 2014. Tokat İli Bitki Yoğunluk Sınıflarının Landsat-7 Etm+ Uydu Görüntüleri Ve Coğrafi Bilgi Sistemleri İle Araştırılması. Gaziosmanpaşa Üniversitesi Ziraat Fakültesi Dergisi, Jafag (2014) 31 (1), 47-53.

- Eray, Ö., 2008. Destek vektör makineleri parametre optimizasyonunun duygu analizi üzerindeki etkisi, DEÜ Mühendislik Fakültesi Mühendislik Bilimleri Dergisi 48, 2008, pp. 87- 88. Erişim Tarihi:22.10.2020.
- Flach, Y., Van Zyl, J. (2012), A time-series approach to estimate soil moisture using polarimetric radar data, IEEE Transactions on Geoscience and Remote Sensing, Vol. 47, No. 8, pp. 2519-2527.
- Gandhi, G.M., Parthiban, S., Thummalu, T., Christy, A. 2015. Ndvi: Vegetation change detection using remote sensing and gis – A case study of Vellore District. 3rd International Conference on Recent Trends in Computing 2015 (ICRTC-2015). Procedia Computer Science 57 (2015) 1199 – 1210
- Gönenç, A., 2019, Uydu Görüntüleri Kullanılarak NDVI ve RVI Bitki Örtüsü İndekslerinin Karşılaştırılması, Yüksek Lisans Tezi, D.Ü, Fen Bilimleri Enstitüsü, Diyarbakır, 22-56.
- Gupta, V.N., P.Kumar, D.K., Mishra & R. Prasad 2015 Destek vektör makinesi, yapay sinir ağı ve LISS IV verilerini kullanarak ekin sınıflandırması için spektral açışleme algoritmalarının karşılaştırılması Uluslararası Uzaktan Algılama Dergisi.
- Gündoğdu, K.S. 2018. Buğday Ekili Parsellerde NDVI Değerlerinin Konumsal ve Zamana Bağlı Değişiminin Belirlenmesi. KSÜ Tarım ve Doğa Dergisi 21(4):492-499.
- Htitiou, N., Tani, H., Wang, X. ve Sonobe, R.,2019. Sentinel-2A görüntülerinden türetilen spektral endeksleri kullanarak ürün sınıflandırması. Çevrimiçi yayın tarihi: 24 Kasım 2019.
- Kandemir, E. 2010. Uzaktan Algılama Tekniğinde Ndvi Değerleri İle Doğal Bitki Örtüsü Tür Dağılımı Arasındaki İlişkilerin Belirlenmesi Üzerine Araştırmalar. Yüksek Lisans Tezi, Ege Üniversitesi Fen Bilimleri Enstitüsü, İzmir.
- Karahanlı, U.G., Radar İnterferometri Tekniği İle Sym Üretimi Ve Doğruluk Değerlendirmeleri. TMMOB Harita ve Kadastro Mühendisleri Odası 11.Türkiye Harita Bilimsel ve Teknik Kurultayı, 2-6 Nisan 2010, Ankara.
- Kobayashi, N., Tani, T., Wang, X., Sonobe,R., 2019, Sentinel-2A görüntülerinden türetilen spektral endeksleri kullanarak ürün sınıflandırması, Ziraat Fakültesi, Shizuoka Üniversitesi, Shizuoka, <https://orcid.org/0000-0002-8330-3730> , 67-90.
- Kumar, P. , D.K. Mishra & R. Prasad ve Gupta, V.N., 2015 Destek vektör makinesi, yapay sinir ağı ve LISS IV verilerini kullanarak ekin sınıflandırması için spektral açışleme algoritmalarının karşılaştırılması Uzaktan Algılama Dergisi.
- Kwak, M., Parkı, D., 2019. Analysis of the Radar Vegetation Index and Potential Improvements. Remote Sens. 2018, 10, 1776.
- Lebrini, Y., Boudhar, A., Hadria, R., Hayat ve Benabdelouahab, T., 2020. Ürün sınıflandırmasını iyileştirmek için Sentinel-2 zaman serisi görüntülerinden alınan

farklı fenolojik bilgilerin karşılaştırmalı bir analizi: bir makine öğrenimi yaklaşımı. Çevrimiçi yayınlama: 20 Mayıs 2020.

- Mazzia, V., Khaliq, A., ve Chiaberge, M., 2019. Tekrarlayan Evrişimli Sinir Ağı (R-CNN) Kullanarak Sentinel-2 Verilerinden Öğrenilen Zamansal Özelliklere Dayalı Arazi Örtüsü ve Mahsul Sınıflandırmasında İyileştirme. Yayınlama: 28 Aralık 2019.
- Meena, P., 2020. Naive Bayes Sınıflandırıcısına Giriş. Towards Data Science, Computer Science @ IIT Roorkee | Data Science enthusiast | Working towards improving digital governance in India.
- Mmamokoma. G., Maponya, A., Niekerk, Z., ve Eric, M. 2019. Sentinel-2 zaman serisi ve makine öğrenimi kullanarak mahsul türlerinin hasat öncesi sınıflandırması. Yayınlama: 28 Aralık 2019.
- Ngugive, M., Tgonuang. G., ve Vegt, L., 2011. European Space Agency (ESA). SAR Basics Tutorial. Erişim: [<http://step.esa.int/docs/tutorials/S1TBX%20SAR%20Basics%20Tutorial.pdf>] Erişim Tarihi: 25.10.2020.
- Rouse, J., Haas, R., Schell, J., Deering, D. (2017). Monitoring the vegetation systems in the Great Plains with ERTS, Third ERTS-1 Symposium, Washington DC, pp. 309-317.
- Wardlow B.D, Brown J.F, Tsegaye T, Hayes M.J, Reed B.C., 2008, The vegetation drought response index: a new integrated approach for monitoring drought stress in vegetation, GIScience and Remote Sensing, 45, ss. 1548-1603.
- Weier J., Herring D. NASA Earth Observatory. Measuring Vegetation (NDVI & EVI) Erişim: [https://earthobservatory.nasa.gov/features/MeasuringVegetation/measuring_vegetation_1.php] Erişim Tarihi: 13.05.2019.
- Weng, Q. 2013. Introduction to Remote Sensing Systems, Data, Applications. Indiana State University. Erişim: [https://www.researchgate.net/publication/299708984_Introduction_to_Remote_Sensing_Systems_Data_and_Applications] Erişim Tarihi: 25.10.2020.
- Wung, L., Fang, J., Dai, S., Li, H., Chen, S. 2020. Comparison and Analysis NDVI and RVI Changes Before and After Typhoon in Hainan Based on HJ-1CCD Satellite Images. The Third International Conference on Agro-Geoinformatics. Beijing, China.
- Yıldız, H., Mermer, A., Ünal, E. ve Akbaş, F., 2012. Türkiye Bitki Örtüsünün NDVI Verileri ile Zamansal ve Mekansal Analizi. Tarla Bitkileri Merkez Araştırma Enstitüsü Dergisi, 2012, 21 (2): 50-56.
- Zheng , Y., Walker, J.P., Gao, Y., Wu, X. ve Monerris, A., 2015. Estimation Of Vegetation Water Content From The Radar Vegetation Index At L-Band Huang Et Al. 2014. Ieee Transactions On Geoscience And Remote Sensing, Vol. 54, No. 2, Page(S): 981 – 989.