



T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

DERİN TRANSFORMER KODLAYICI TEKNİĞİ VE FARKLI ZAMAN SERİSİ
UYDU GÖRÜNTÜLERİ KULLANILARAK PAMUK VE MISIR BİTKİ
ALANLARININ BELİRLENMESİ

Reyhan ŞİMŞEK BAĞCI

YÜKSEK LİSANS TEZİ

ELEKTRİK-ELEKTRONİK MÜHENDİLİĞİ ANABİLİM DALI

Eylül-2022
BATMAN
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Reyhan ŞİMŞEK BAĞCI tarafından hazırlanan “DERİN TRANSFORMER KODLAYICI TEKNİĞİ VE FARKLI ZAMAN-SERİSİ UYDU GÖRÜNTÜLERİ KULLANILARAK PAMUK VE MISIR BİTKİ ALANLARININ BELİRLENMESİ” adlı tez çalışması 28/09/2022 tarihinde aşağıdaki jüri tarafından oy birliği ile Batman Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Prof. Dr. Mehmet Sıraç Özerdem

.....

Danışman

Dr.Öğr.Üyesi Emrullah ACAR

.....

2.Danışman

Dr. Öğr. Üyesi Ömer Türk

.....

Üye

Dr. Öğr. Üyesi Abdulkерim Öztekin

.....

Üye

Dr. Öğr. Üyesi Musa Yılmaz

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Osman PAKMA
Lisansüstü Eğitim Enstitüsü Müdürü

Dr. Öğr. Üyesi Ömer TÜRK bu tez çalışmasının ikinci danışmanıdır.

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

Reyhan ŞİMŞEK BAĞCI

28.09.2022

ÖZET

YÜKSEK LİSANS

DERİN TRANSFORMER KODLAYICI TEKNİĞİ VE FARKLI ZAMAN-SERİSİ UYDU GÖRÜNTÜLERİ KULLANILARAK PAMUK VE MISIR BİTKİ ALANLARININ BELİRLENMESİ

Reyhan ŞİMŞEK BAĞCI

**Batman Üniversitesi Lisansüstü Eğitim Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı**

Danışman: Dr. Öğr. Üyesi Emrullah ACAR

2022, 69 Sayfa

Jüri

Prof. Dr. Mehmet Sıraç ÖZERDEM

Dr. Öğr. Üyesi Emrullah ACAR

Dr. Öğr. Üyesi Ömer TÜRK

Dr. Öğr. Üyesi Abdulkarim ÖZTEKİN

Dr. Öğr. Üyesi Musa YILMAZ

Türkiye orta kuşakta yer aldığından dolayı tarımsal alanda zengin bir ülkedir. Tarımsal alandaki ürünlerin kısa sürede ve doğru bir şekilde tespit edilmesi oldukça önemlidir. Uzaktan algılamadan elde edilen uydu görüntüleri sayesinde tarımsal ürünlerin tespiti gelişimi ve yıllık ürün tahmini gibi birçok konuda bilgi elde edilebilmektedir. Bu çalışmada, tarımsal ürünlere ait Sentinel-1 ve Landsat-8 uydu görüntü indeksleri ve derin mimarisi birlikte kullanılarak tarımsal ürünlerden Mısır ve Pamuk'un tespitinin yapılması amaçlanmıştır.

İlk aşamada tespiti yapılması istenen tarımsal ürünlerin Sentinel-1 ve Landsat-8 uydu görüntülerini elde etmek için pilot alan belirlenmiştir. Tarım ürünleri seçilirken gelişme ve hasat zamanları yakın olan mısır ve pamuk ürünlerinin yoğunlukta olduğu bir tarım arazisi seçilmiştir. Bu pilot alandan daha sonra 100 örnek noktaya ait koordinatlar GPS yardımıyla alınmış ve bu koordinatlar Sentinel-1 ve Landsat-8 uydu görüntülerine aktararak yansıma değerleri elde edilmiştir. Görüntülerin yansıma değerlerini hesaplamak için tespiti yapılacak tarımsal ürünlerin gelişim ve hasat zamanlarının birbirine yakın olduğu 2016-2021 döneminin Haziran, Temmuz, Ağustos, Eylül ayları tercih edilmiştir. Çalışmada kullanılan veri seti, Google Earth Engine Code Editor (GEE-CE) yardımıyla elde edilmiş ve 2016-2021 yılları arasındaki Haziran, Temmuz, Ağustos, Eylül aylarına ait Sentinel-1 uydu görüntüsü için toplam 434 görüntü ve Landsat-8 için ise toplam 693 görüntüden oluşmaktadır.

Son aşamada, elde edilen yansıma değerleri üç farklı kategoride sınıflandırılmıştır. Bunlar:1-) Sadece Sentinel-1 bantlarıyla sınıflandırma, 2-) Sadece Landsat-8'in B1-B7 bantlarıyla sınıflandırma, 3-) Hem Sentinel-1 hem de Landsat-8'in B1-B7 bantlarıyla sınıflandırma şeklindedir. Bu üç farklı yansıma değerleri, Transformer Derin Öğrenme ağı girişine verilerek, tarımsal ürünler (Mısır ve Pamuk) tespit edilmiştir. Birinci sınıflandırmada yalnız Sentinel-1 uydu görüntülerinin yansıma değerleri kullanıldığında %85 sınıflandırma doğruluğu elde edilmiştir. İkinci sınıflandırmada, Landsat-8'in B1-B7 bantlarının uydu görüntülerinin yansıma değerleri için %95 sınıflandırma doğruluğu bulunmuştur. Üçüncü sınıflandırma da ise Sentinel-1 ve Landsat-8'in B1-B7 bantlarının uydu görüntüleri yansıma değerleri birlikte kullanıldığında %87,5 ortalama doğruluk değeri gözlemlenmiştir.

Anahtar Kelimeler: Derin Öğrenme, Landsat-8, Mısır, Pamuk, Sentinel-1, Uzaktan Algılama, Tarımsal Alan Belirleme

ABSTRACT

MS THESIS

DETERMINATION OF COTTON AND CORN PLANT FIELDS BY EMPLOYING DEEP TRANSFORMER ENCODER TECHNIQUE AND DIFFERENT TIME-SERIES SATELLITE IMAGES

Reyhan ŞİMŞEK BAĞCI

**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

2022, 69 Pages

Jury

Prof. Dr. Mehmet Sıraç ÖZERDEM

Asst. Prof. Dr. Emrullah ACAR

Asst. Prof. Dr. Ömer TÜRK

Asst. Prof. Dr. Abdulkерim ÖZTEKİN

Asst. Prof. Dr. Musa YILMAZ

Turkey is a rich country in agriculture because it is located in the middle belt. It is very important to determine the products in the agricultural field in a short time and accurately. Thanks to the satellite images obtained from remote sensing, information can be obtained on many subjects such as the development of agricultural products detection and annual product forecasting. In this study, it is aimed to detect corn and cotton from agricultural products by using Sentinel-1 and Landsat-8 satellite image indexes and deep architecture of agricultural products together.

In the first stage, a pilot area was determined to obtain Sentinel-1 and Landsat-8 satellite images of the agricultural products to be determined. While choosing agricultural products, an agricultural land with high corn and cotton products, whose development and harvest times are close, was chosen. Afterwards, the coordinates of 100 sample points from this pilot area were taken with the help of GPS and these coordinates were transferred to Sentinel-1 and Landsat-8 satellite images and reflectance values were obtained. In order to calculate the reflection values of the images, the months of June, July, August and September of the 2016-2021 period, when the development and harvest times of the agricultural products to be determined are close to each other, were preferred. The data set used in the study was obtained with the help of the Google Earth Engine Code Editor (GEE-CE), and a total of 434 images for Sentinel-1 satellite images and 693 images for Landsat-8 for the months of June, July, August, September between 2016-2021. consists of images.

At the last stage, the reflection values obtained were classified into three different categories. These are: 1-) Classification with only Sentinel-1 bands, 2-) Classification with B1-B7 bands of Landsat-8 only, 3-) Classification with B1-B7 bands of both Sentinel-1 and Landsat-8. These three different reflection values were given to the Transformer Deep Learning network input and agricultural products (Corn and Cotton) were determined. In the first classification, 85% classification accuracy was obtained when only the reflectance values of Sentinel-1 satellite images were used. In the second classification, 95% classification accuracy was found for the reflectance values of the satellite images of the B1-B7 bands of Landsat-8. In the third classification, when the reflectance values of the B1-B7 bands of Sentinel-1 and Landsat-8 were used together, an average accuracy value of 87,5% was observed.

Keywords: Deep Learning, Landsat-8, Corn, Cotton, Sentinel-1, Remote Sensing, Agricultural Land Designation

ÖNSÖZ

Bu çalışma; Diyarbakır Tarım Müdürlüğü Hibe Destek kapsamında kontrol edilen tarım arazisi alanları kullanılmıştır. Desteklerinden ötürü Harita Yüksek Mühendisi Muhyettin Zuğurlu'ya teşekkür ederim.

Bu çalışma süresince her anlamda yardımını, bilimsel katkılarını ve tecrübelerini hiçbir zaman esirgemeyen değerli danışman hocalarım Dr. Öğr. Üyesi Emrullah ACAR ve Dr. Öğr. Üyesi Ömer TÜRK'e, çalışmalarım boyunca her konuda destek veren Cengiz ASLAN ve Müslime ALTUN'a teşekkür ederim.

Ön çalışmalarımın hazırlanması sırasında her konuda fedakârlığını gösteren, maddi ve manevi yardımlarını esirgemeyen aileme ve eşim Yaşar BAĞCI'ya sonsuz şükranlarımı sunarım.

Reyhan ŞİMŞEK BAĞCI
BATMAN-2022

İÇİNDEKİLER

TEZ BİLDİRİMİ	İV
ÖZET	İV
ABSTRACT.....	V
ÖNSÖZ	VI
İÇİNDEKİLER.....	VII
ÇİZELGE LİSTESİ.....	IX
ŞEKİLLER LİSTESİ	İV
KISALTMA VE SİMGELER.....	İV
1.GİRİŞ	1
2. KAYNAK ARAŞTIRMASI	3
2.1. I. Gruba Ait Literatür Çalışmaları	3
2.2.II. Gruba Ait Literatür Çalışmaları.....	4
2.3.III. Gruba ait Literatür Çalışmaları	6
3. MATERYAL VE YÖNTEM.....	9
3.1. Çalışma Alanı	10
3.2. Veri toplama.....	11
3.2.1 Uydu görüntüleri tarihlerinin seçimi	11
3.2.2 Google earth engine	11
3.2.3 Sentinel-1 uydu görüntüleri – SAR (Sentetik Açıklıklı Radar).....	12
3.2.4 Landsat	14
3.2.4.1 Landsat-8.....	15
3.3. Ön İşlem.....	18
3.3.1 Sentinel-1 görüntüsü ön işlemleri	19
3.3.2 Landsat-8 görüntüsü ön işlemleri	23
3.4. Özellik Çıkarımı.....	34
3.5. GPS Verilerinin Google Earth Engine Görüntüsüne İşlenmesi.....	35
3.6. Derin Öğrenme Teknikleri.....	36
3.6.1.Otomatik kodlayıcı (Auto encoder).....	37
3.6.2. Evrimsel sinir ağı (CNN).....	39
3.6.3. Transformer derin öğrenme mimarisi	40

3.6.3.1. Konumsal kodlama.....	41
3.6.3.2. Çok başlı dikkat mekanizması.....	42
3.6.3.3. Noktasal ileri besleme ağ katmanı.....	42
4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....	43
4.1. Mısır ve Pamuk Bitkilerine Ait Yansıma Değerlerinin Hesaplanması.....	43
4.2. Derin Öğrenme Teknikleri yardımıyla Yansıma Değerlerinden Ürün Tespitine ait Bulgular ..	43
4.2.1. Sentinel-1 yansıma değerleri ve DTK yaklaşımından hesaplanan performans metrikleri	45
4.2.2. Landsat-8 yansıma değerleri ve DTK yaklaşımından hesaplanan performans metrikleri	47
4.2.3. Sentinel-1 ve Landsat-8 yansıma değerleri ve DTK yaklaşımından hesaplanan performans metrikleri.....	48
4.3. Bulguların Değerlendirilmesi.....	49
5. SONUÇLAR VE ÖNERİLER.....	51
KAYNAKLAR	52
ÖZGEÇMİŞ	57

ÇİZELGE LİSTESİ

Çizelge 3.1. Çalışmada kullanılan uydu görüntülerinin tarihleri.....	11
Çizelge 3.2. Landsat programında bulunan uyduların özellikleri	14
Çizelge 3.3. Landsat-8 uydu görüntüsünün bantlarına ilişkin bazı bilgiler.....	16
Çizelge 3.4. Landsat-8 OLI uydu görüntüsüne ilişkin genel bilgiler	17
Çizelge 3.5. Landsat-8 OLI uydu görüntüsünün bantlarına ilişkin bazı bilgiler	17
Çizelge 3.6. TIRS Spektral bant özellikleri	18
Çizelge 4.1. Sentinel-1'e ait yansımaya değerleri ve DTK yaklaşımına ait performans metrikleri.....	46
Çizelge 4.2. Landsat-8'e ait yansımaya değerleri ve DTK yaklaşımına ait performans metrikleri.....	48
Çizelge 4.3. Sentinel-1 ve Landsat-8'e ait yansımaya değerleri ve DTK yaklaşımına ait performans metrikleri	49
Çizelge 4.4. Çalışmada üç farklı gruba ait DTK yaklaşımından elde edilen sonuçların karşılaştırılması.....	49
Çizelge 4.5. Literatürdeki benzer çalışmalara ait performans değerlerinin karşılaştırmalı tablosu.....	50

ŞEKİLLER LİSTESİ

Şekil 3.1. Ürün belirleme için önerilen blok diyagram	9
Şekil 3.2. Çalışma alanının Google Earth'daki konumu	10
Şekil 3.3. Google Earth üzerinde çalışma alanının parsellenmiş görünümü	10
Şekil 3.4. Google Earth çalışma alanı noktaların görünümü	18
Şekil 3.5. QGIS'e aktarılan noktaların görünümü	19
Şekil 3.6. Pilot Alana ait Haziran 2021 tarihli Sentinel-1 uydu ham görüntüsü	19
Şekil 3.7. Pilot alana ait Haziran 2021 tarihli Sentinel-1 VV-VH bantlarına ait görüntüler	20
Şekil 3.8. Pilot Alana ait Temmuz 2021 tarihli Sentinel-1 uydu ham görüntüsü	20
Şekil 3.9. Pilot alana ait Temmuz 2021 tarihli Sentinel-1 VV-VH bantlarına ait görüntüler	21
Şekil 3.10. Pilot Alana ait Ağustos 2021 tarihli Sentinel-1 uydu ham görüntüsü	21
Şekil 3.11. Pilot alana ait Ağustos 2021 tarihli Sentinel-1 VV-VH bantlarına ait görüntüler	22
Şekil 3.12. Pilot Alana ait Eylül 2021 tarihli Sentinel-1 uydu ham görüntüsü	22
Şekil 3.13. Pilot alana ait Eylül 2021 tarihli Sentinel-1 VV-VH bantlarına ait görüntüler	23
Şekil 3.14. Pilot alana ait Haziran 2021 tarihli Landsat-8 uydu ham görüntüsü	24
Şekil 3.15. Haziran 2021 tarihli Landsat-8 uydusunun bantlarına ait görüntüler	26
Şekil 3.16. Pilot alana ait Temmuz 2021 tarihli Landsat-8 uydu ham görüntüsü	26
Şekil 3.17. Temmuz 2021 tarihli Landsat-8 uydusunun bantlarına ait görüntüler	29
Şekil 3.18. Pilot alana ait Ağustos 2021 tarihli Landsat-8 uydu ham görüntüsü	29
Şekil 3.19. Ağustos 2021 tarihli Landsat-8 uydusunun bantlarına ait görüntüler	31
Şekil 3.20. Pilot alana ait Eylül 2021 tarihli Landsat-8 uydu ham görüntüsü	32
Şekil 3.21. Eylül 2021 tarihli Landsat-8 uydusunun bantlarına ait görüntüler	34
Şekil 3.22. Google Earth çalışma alanı noktaların görünümü	35
Şekil 3.23. QGIS ile seçilen 100 farklı GPS verisinin konum bilgilerine göre dağılımı	36
Şekil 3.24. Pilot tarım alanında bulunan 100 farklı GPS verisinin konum bilgilerine göre dağılımı	36
Şekil 3.25. Yapay sinir ağı şeması (Bakshi, 2021)	37
Şekil 3.26. Basit bir oto kodlayıcı ağ yapısı (Shin ve ark 2013)	38
Şekil 3.27. Klasik bir CNN mimarisi (Britz 2015)	39
Şekil 3.28. Temel transformer model mimarisi (Vaswani ve ark 2017)	41
Şekil 4.1. Karışıklık matrisi tablosu	43
Şekil 4.2. ROC Eğrisi Grafiği	45
Şekil 4.3. Sentinel-1'e ait yansımalar ve DTK yaklaşımına ait karışıklık matrisi tablosu	46
Şekil 4.4. Sentinel-1'e ait yansımalar ve DTK yaklaşımına ait ROC eğrisi grafiği	46
Şekil 4.5. Landsat-8'e ait yansımalar ve DTK yaklaşımına ait karışıklık matrisi tablosu	47
Şekil 4.6. Landsat-8'e ait yansımalar ve DTK yaklaşımına ait ROC eğrisi grafiği	47
Şekil 4.7. Sentinel-1 ve Landsat-8'e ait yansımalar ve DTK yaklaşımına ait karışıklık matrisi tablosu	48
Şekil 4.8. Sentinel-1 ve Landsat-8'e ait yansımalar ve DTK yaklaşımına ait ROC eğrisi grafiği	49

KISALTMA VE SİMGELER

AtBiLSTM	: Dikkate Dayalı Çift Yönlü Uzun Kısa Süreli Bellek
Bi-LSTM	: Uzun-Kısa Süreli Bellek
CART	: Regresyon Ağaçları
CNN	: Evrişimli Sinir Ağlarını
CTree	: Karmaşık Ağaç
DCNN	: Derin Evrişimli Sinir Ağlarını
DLF	: Karar Düzeyinde Füzyon
DNN	: Derin Sinir Ağları
DSCRNN	: Evrişim Tekrarlayan Sinir Ağı
DT	: Karar Ağacı
DTK	: Derin Transformer Kodlayıcı
ETM	: Geliştirilmiş Tematik Haritalandırıcı
EW	: Ekstra Geniş Alan
GEE	: Google Earth Engine
GEE-CE	: Earth Engine Code Editor
GYSA	: Geri Yayılımlı Sinir Ağı
GRD	: Yer Aralığı Algılandı
GRU	: Geçitli Tekrarlayan Birim
GYSA	: Geri Yayılımlı Sinir Ağı
HH + HV	: Yatay Gönderme/Dikey Alma
IW	: Interferometrik Geniş Alan Modu
k-NN	: K-En Yakın Komşu
LSTM	: Uzun-Kısa Süreli Bellek
LSTM-MTL	: LSTM Tabanlı Çok Görevli Öğrenme
MSA	: Çok başlı Öz Dikkat
MSS	: Multispektral Tarayıcı Sistemi
NB	: Normal Bayes
NIR	: Yakın Kızılötesi
OA	: Genel Doğruluğa
OLI	: Operasyonel Arazi Görüntüleyici
QGIS	: Quantum Coğrafi Bilgi Sistemi

RCNN	: Tekrarlayan Evrişimli Sinir Ağlarını
RDT	: Regresyon Karar Ağaçları
RF	: Rastgele Orman
RNN	: Tekrarlayan Sinir Ağı
SAR	: Sentetik Açıklıklı Radar
SM	: Stripmap
SRTM	: Mekik Radar Topografya Misyonu
SSV	: Spektral Benzerlik Değeri
SVM	: Destek Vektör Makinesi Sınıflayıcısını
SWIR	: Kısa Dalga Kızılötesi
DTK	: Derin Transformer Kodlayıcı
TDÖ	: Transformer Derin Öğrenme
TIR	: Termal Kızılötesi
TIRS	: Termal Kızılötesi Algılayıcı
TM	: Tematik Haritalandırıcı
UA	: Uzaktan Algılama
VH	: Dikey İletim Ve Yatay Alım
VIS	: Görünür Işığı
VNIR	: Görünür ve Yakın Kızılötesi
VV	: Dikey Gönderme/Dikey Alma
VV + VH	: Dikey Gönderme/Yatay Alma
WV	: Dalga

1.GİRİŞ

Uzaktan algılama teknolojisinden elde edilen bilgiler, canlı türlerinin yaşam alanlarının belirlenmesi, detaylandırılması, türlerin dağılımı ve alansal değişimi tespit etmeyi sağlamaktadır. Klasik yersel ölçümlere dayalı yöntemlerde ise bu işlem zaman alıcı, maliyetli, zor ve karmaşıktır. Bundan dolayı, uzaktan algılamada kullanılan araçlar ve veriler sayesinde daha kısa sürede ve az maliyetle sonuçlara gidilebilmektedir (Kerr ve ark 2003).

Uzaktan algılama sistemleri temel olarak iki yaklaşım üzerine kurulmuştur. Bu yaklaşımlardan ilki, enerjisini doğrudan kendi içerisinde üreten aktif sistemlerdir. Bu sistemler içinde en çok kullanılan görüntüleme tekniklerinin başında Sentinel-1 Sentetik Açıklıklı Radar (SAR) gelmektedir. Sentinel-1, ürettiği elektromanyetik sinyalleri antenleri aracılığıyla yaymakta ve görüntülediği yüzeyden yansıyan sinyalleri antenlerinde toplamaktadır. Ayrıca, Sentinel-1 radyo spektrumunda sinyal kullandığı için atmosfer ve hava koşullarından etkilenmemektedir. Aktif bir sensör olduğundan dolayı da güneş ışığına ihtiyaç duymadan görüntü sağlayabilmektedir (Teke ve ark 2016). Bu yaklaşımlardan ikincisi ise, enerjisini güneşten alan pasif sistemlerden oluşmaktadır. Pasif sistemler içinde en çok kullanılan görüntüleme tekniklerinden biri de Landsat-8 sensörüdür.

Bilgi taşıyıcı olarak kullanılan uzaktan algılama, vakumdaki ışık şiddetinin çeşitli dalga boylarında hareket eden elektromanyetik radyasyonlarından oluşmaktadır. Uzaktan algılamada en elverişli dalga boyları, görünür ışık (VIS), yakın kızıl ötesi (NIR), kısa dalga kızılötesi (SWIR), termal kızılötesi (TIR) ve mikrodalga bantlarını kapsamaktadır. Pasif uzaktan algılama sensörleri, nesnelerden yayılan veya yansıyan radyasyonu kaydederken, aktif sensörler araştırılacak hedefle etkileşime giren ve ölçüm cihazına geri dönüp radyasyonunu yaymaktadır (Wójtowicz ve ark.2016).

Aktif ve pasif uzaktan algılama tekniklerinin yaygın kullanım alanlarından biri de tarımsal arazilerdir. Bu teknikler sayesinde klasik tarımda kullanılan tek bir yöntem yerine tarım arazilerine özgü yöntemler geliştirilmektedir. Dahası, tarımsal alanda kullanılan ürünlerin tespitinde, uzaktan algılama verilerinin işlenmesi, depolanması, analizi ve görselleştirilmesi, hassas tarımın gelişiminde büyük önem arz etmektedir (Huang ve ark 2018).

Bu çalışmanın temel amacı, farklı zaman-serisi Sentinel-1 ve Landsat-8 uydu görüntüleri kullanılarak Diyarbakır'ın Bismil ilçesine bağlı Tepe Mahallesi'ne bağlı pilot alanı üzerinde bulunan pamuk ve mısır bitkilerine ait alanların derin transformer kodlayıcı

tekniki yardımıyla tespit edilmesini sağlamaktır. Dahası, uydu görüntülerinden elde edilen parametrelerin ayrı ayrı ve birlikte kullanılarak sınıflandırma performansları üzerindeki etkilerini gözlemleyerek, en uygun uydu görüntü indekslerini belirlemeye çalışmaktır.

Tez çalışmasının birinci bölümünde, tespiti edilecek tarımsal mahsullerin türleri ve ekili oldukları alanın belirlenmesi hakkında bilgi verilmiştir. Seçilen pilot bölgeye ait parsellemeler baz alınarak bölge üzerinde koordinat noktaları alınması, koordinatlara karşılık gelen ürünün tespit edilmesi ve hangi dönemlere ait görüntünün kullanılacağı hakkında açıklama yapılmıştır.

Tezin ikinci bölümünde, uzaktan algılama teknikleriyle ilgili literatür taramasına yer verilmiştir.

Tezin Üçüncü bölümünde Google Earth Engine, Sentinel-1 ve Landsat-8 uydusu hakkında bilgi verilmiştir.

Son olarak, tezin dördüncü bölümünde Google Earth Engine code editor platformu üzerinden, Sentinel-1 ve Landsat-8 uydularından alınan farklı zaman-serisi görüntülerinin yansıma değerlerinden bahsedilmiştir. Ayrıca, bu indekslerin derin öğrenmeye aktarılması ve derin öğrenmeden elde edilen sonuçlara ait istatistiksel analizlere yer verilmiştir.

2. KAYNAK ARAŞTIRMASI

Bu bölümde uzaktan algılama sistemlerinden faydalanılarak tarım alanlarına ait uydu görüntülerinin yansıma değerleri ile tarımsal araziler üzerindeki ürünlerin tahmini için gerekli literatür taramaları yapılmış ve yapılan bu çalışmalar 3 ana grupta toplanmıştır. Bu gruplar sırasıyla şu şekildedir;

- I. Grup: Pasif Uydu Görüntüleme Sistemleri ve Makine Öğrenme Yöntemleri Yardımıyla Tarımsal Ürünlerin Tespiti
- II. Grup: Aktif Görüntüleme Sistemleri ve Makine Öğrenme Yöntemleri Yardımıyla Tarımsal Ürünlerin Tespiti
- III. Grup: Hem Aktif hem de Pasif Uydu Görüntüleme Sistemleri ve Makine Öğrenme Yöntemleri Yardımıyla Tarımsal Ürünlerin Tespiti

2.1. I. Gruba Ait Literatür Çalışmaları

Schultz ve ark. (2015), iki çok zamanlı Landsat-8 görüntüsü (Ağustos 2013 ve Ocak 2014) kullanarak şeker kamışı, soya fasulyesi, manyok, fıstık ve diğerleri olmak üzere beş ürünü sınıflandırmaya çalışmışlardır. Görüntü sınıfını ve Rastgele Orman (RF) sınıflandırmasını birleştiren denetimli nesne tabanlı sınıflandırma geliştirmişlerdir. Beş ürünü sınıflandırılırken %80'lik bir genel doğruluğa ulaşmışlardır.

Mulyono ve ark. (2016), Landsat-8 görüntülerini kullanarak şeker kamışı ekimini tespit etmeye çalışmışlardır. Karışık veriler ve az eğitim örneklerine rağmen iyi performans sağlayan makine öğrenme tekniği olan Destek Vektör Makinesi (SVM) sınıflandırıcısını önermişlerdir. Yapılan çalışmaların sonucuna bakıldığında şeker kamışı mahsulünü sınıflandırmada %90.78' lik iyi bir doğruluk performansı sağlamışlardır.

Ikasari ve ark. (2016), Landsat-8 uydu görüntülerinden faydalanılarak çeltik büyüme evrelerini sınıflandırmaya çalışmışlardır. Elde edilen sayısal verileri sınıflandırmak için derin öğrenmenin sınıflandırma yöntemlerinden Derin Sinir Ağını (DNN) ve bir boyutlu (1-D) Evrişimsel Sinir Ağını (CNN) kullanmışlardır. Çalışmada, geleneksel makine öğrenme sınıflandırıcılarına (SVM, RF, vb.) göre daha iyi sonuçlar elde edilmiştir.

Zhou ve ark. (2017), Landsat-8 uzaktan algılama görüntülerini kullanarak fıstık ekim alanını haritalamaya çalışmışlardır. Tarımsal alanda mahsul sınıflandırmada CNN mimarisi kullanmışlardır. Çalışmada, CNN tabanlı sınıflandırma mimarisinden %96,42 sınıflandırma doğruluğu elde edilmiştir.

Gilbertson ve ark. (2017) çalışmalarında, Akdeniz ikliminde mahsullerin sınıflandırılmasında pan-keskinleştirme çok zamanlı Landsat-8 görüntülerinin etkilerini

araştırmışlardır. Yedi ana mahsul türünün büyüme adımlarını içeren beş Landsat-8 görüntüsü elde ederek, Karar Ağaçları (DT), k-en yakın komşu (k-NN), SVM ve RF sınıflandırıcılarında değerlendirmişlerdir. Bu sınıflandırıcılardan SVM en iyi sonucu vermiş olup Pan-keskinleştirilmiş görüntü kullanıldığında yaklaşık %96'lık bir genel doğruluk elde edilmiştir. Sonuç olarak tarım alanların mahsul sınıflandırılmasında Pan-keskinleştirme işleminin önemli bir etkisi olduğu tespit edilmiştir.

Zhang ve ark. (2018) çeltik-pirinç ürünlerini haritalamak için çok zamanlı Landsat-8 verilerini kullanmıştır. Sınıflandırıcı olarak uzaktan algılamada veri analizinde önemli etkiye sahip CNN mimarisinden faydalanmışlardır. Elde edilen doğruluk 97.06'lık olup, geleneksel makine öğrenimi yöntemlerinden daha iyi sonuç elde edilmiştir.

Pareeth ve ark. (2019) Landsat-8 uydu verilerini kullanarak üç ürün yılı için beş farklı sulama arazi kullanım türlerini çıkarmaya çalışmışlardır. Sonuç olarak, Rastgele Orman (RF) makine öğrenme algoritmasını kullanarak arazi kullanım türünü ortalama 0.98 doğruluk ile tespit etmişlerdir.

Jamali (2020) arazi örtüsü haritalaması için Landsat-8 görüntülerinden yararlanarak makine öğrenme tekniklerinden SVM ve Karmaşık Ağaç (CTree) yöntemlerini kullanılmıştır. Elde edilen %91,28 ve %88 doğruluk değerleriyle bilinen DNN ve Geri Yayımlı Sinir Ağı (GYSA) gibi yöntemlere göre daha iyi sonuçlar elde edilmiştir.

Shin ve ark. (2021) uydu görüntülerini sınıflandırmak için Landsat-8 görüntülerinden faydalanmışlardır. Elde edilen veri setlerini test etmek için geleneksel sınıflandırma yönteminden farklı olarak görüntü sınıflandırması için yeni bir makine öğrenmesi olan piksel tabanlı yaklaşım yöntemini önermişlerdir. Oluşturulan dört test veri setinden sırasıyla, %99,99, %99,96, %99,45 ve %98,03 doğruluk elde ederek önceki sınıflandırıcılara göre %8,52 daha yüksek performans sağlamışlardır.

2.2.II. Gruba Ait Literatür Çalışmaları

Xu ve ark. (2018) bu çalışmalarında daha önce yapılan çok zamanlı SAR arazi sınıflandırılmasında yetersiz olan zamansal bilgilerin karakteristiklerini kullanarak mahsul sınıflandırmaya çalışmışlardır. Bu çalışmanın etkisini anlamak için iki set Sentinel-1 SAR zaman serisi verisinden faydalanmışlardır. Makine öğrenme yaklaşımı olarak Spektral Benzerlik Değeri (SSV), DT ve Naive Bayes (NB) sınıflandırıcılarını kullanmışlardır. SSV'de hem VH hem de VV bantlarında daha yüksek doğruluk değeri elde edilmiştir.

Ndikumana ve ark. (2018) Sentinel-1 uzaktan algılama verilerini kullanarak farklı tarım arazi örtüsü haritalamak amacıyla yeni derin öğrenme tekniklerini incelemişlerdir. Veriler hem makine öğrenimi hem derin öğrenme ile test edilmiştir. Klasik makine öğrenmesi yaklaşımlarıyla (k-NN, RF ve SVM), %86 F-skor/doğruluk elde edilirken, derin öğrenme yöntemi olarak Tekrarlayan Sinir Ağı (RNN) tabanlı Uzun-Kısa Bellek (LSTM) mimarisinden ve Geçitli Tekrarlayan Birim (GRU) sınıflandırıcı ile %96 F-skor/doğruluk elde edilmiştir. Sonuçlara bakılarak klasik yöntemlere nazaran RNN tabanlı tekniklerin ileride uzaktan algılama zaman serilerinin incelemelerinde önemli bir etkiye sahip olacağını ileri sürmüşlerdir.

Gao ve ark. (2019) İki farklı çalışma alanında bulunan tarım ürünlerini sınıflandırmada büyük performans sağlayan Sentinel-1 SAR zaman serilerinden yararlanmışlardır. Sentinel-1'den elde edilen verileri SVM sınıflandırma yöntemi kullanarak test etmişlerdir. İki çalışma bölgesi için elde edilen genel doğruluk sırasıyla %94,98 ve %90,20 tespit etmişlerdir. Elde edilen sonuçlara bakıldığında SVM sınıflandırma yöntemi diğer yöntemlere göre iyi performans sağlamıştır.

Crisóstomo ve ark. (2020) pirinç mahsullerini tespit etmek için Sentinel-1 zaman serisi görüntülerine farklı modeller uygulamışlardır. SVM, RF, k-NN ve NB geleneksel makine öğrenmesi tekniklerini kullanmışlardır. Bu modellere ek olarak Derin Öğrenme mimarilerinden RNN mimarisinden de faydalanmışlardır. RNN mimarisinden de en çok kullanılan yaklaşımlardan biri LSTM mimarisi ve Çift Yönlü LSTM (Bi- LSTM) mimarisi yaklaşımlarını kullanmışlardır. Sonuçlar karşılaştırıldığında kullanılan derin öğrenme mimarilerinden RNN modeli, geleneksel makine öğrenme yöntemlerinden daha kısa sürede ve %98'den büyük doğruluk ile yüksek performans sağlamıştır.

Qu ve ark. (2020) mahsul sınıflandırması için önceki deneylerden farklı olarak Sentinel-1 zaman serisindeki geri saçılım sinyalleri yerine karmaşık değerli kovaryans matrisi kullanmışlardır. Karmaşık tarım ürünlerin tespitinde klasik makine öğrenimi yerine Tekrarlayan CNN (RCNN) mimarisi önermişlerdir. Elde ettikleri sonuçlara bakılarak önceki yapılan çalışmalarda zor olan çeşitli tarım alanlarını kısa sürede ve doğru bir şekilde ayırt edebilmişlerdir.

Son ve ark. (2021) Sentinel-1 VV ve VH uydu görüntüleri kullanarak parçalı pirinç mahsullerini sınıflandırmak için nesne tabanlı bir yaklaşımdan faydalanmışlardır. Makine öğrenme yöntemlerinden DT ve RF yöntemini kullanmışlardır. DT kullanılarak elde edilen genel doğruluk %96,3'e ulaşırken, RF sınıflandırıcı kullanılarak genel

doğruluğu %96,6 olarak elde etmişlerdir. Elde edilen veriler ulusal veriler ile karşılaştırıldığında en iyi performans elde edilmiştir.

Wei ve ark. (2021) farklı yıllardaki (2017, 2018 ve 2019) Sentinel-1 verilerinden faydalanarak pirinç ürünün mekânsal dağılımını tespit etmeye çalışmışlardır. Bunun için derin öğrenme tekniklerinden Evrişimli Sinir Ağı yaklaşımı (Convolutional Neural Networks-CNN) olan U-Net'ten uyarlanmış yöntem önermişlerdir. Yapılan deneyler sonucunda pirinç mahsulleri tespitinde iyi performans sergilediğini tespit etmişlerdir.

Lin ve ark. (2022) geniş alanda pirinç ürününü mekânsal dağılımını haritalamak amacıyla Sentinel-1 SAR verilerinden faydalanmışlardır. Bu verileri derin öğrenme modellerinden LSTM tabanlı Çok Görevli Öğrenme (LSTM-MTL) modelini kullanmışlardır. Yapılan testler sonucunda UKBA -ÇGÖ modelinden %98,3 sınıflandırma doğruluğu elde edilmiştir.

2.3.III. Gruba ait Literatür Çalışmaları

Fonteh ve ark. (2016) Sentinel-1 ve Landsat uydu görüntülerini kullanarak yerleşim, su, mangrovlar ve diğer bitki örtüsü ve kauçuk gibi arazi örtüsünü sınıflandırmaya çalışmışlardır. Sınıflandırma işlemi için çeşitli geleneksel görüntü işleme teknikleri ve SVM algoritması kullanılmıştır. Tüm Landsat spektral bantları, Landsat'ın en iyi üç bandı (5, 6, 7), Landsat ve SAR entegrasyonu ve SVM sınıflandırıcısı ile SAR görüntüleri kullanılarak yapılan sınıflandırma sonuçları, genel doğruluk değerlendirmesi olarak %88,71, %91,96, %88,59'luk bir genel doğruluk sağlamıştır. En yüksek doğruluğu Landsat'ın üç bandı (5, 6, 7) ile elde edilmiştir.

Demarez ve ark. (2019) Sentinel-1, Landsat-8 ve Mekik Radar Topografya Misyonu (SRTM) dijital yükseklik modeli ile birlikte kullanarak Fransa'nın güneybatısının ılıman bir bölgesinde sulanan mısır ürünlerini sınıflandırılmayı amaçlamışlardır. Bunu gerçekleştirmek için makine öğrenme yönteminden RF algoritmasını kullanmışlardır. Elde edilen sonuçlar Sentinel-1 ve Landsat-8 görüntülerinin ikisi kullanılarak elde edilen sonuçlar Sentinel-1 ve Landsat-8 görüntülerin ayrı ayrı kullanılarak elde edilen sonuçlara göre daha iyi doğruluk elde edildiğini tespit etmişlerdir.

Shimizu ve ark. (2019) makine öğrenme algoritmasından RF algoritması kullanarak tropikal mevsimlik ormanlardaki bozulmaları belirlemek için Landsat-8 ve Sentinel-1 zaman serisi verilerini kullanarak tespit etmeye çalışmışlardır. Yapılan çalışma sonucunda yalnızca Landsat-8 verileri ile %78,3 doğruluk, Sentinel-1 verilerinden ise %75,5 doğruluk elde etmişlerdir. Bunun yanında, Landsat-8 ve Sentinel-1 verileri

birleştirildiğinde %83,6'lık doğruluk elde edilmiştir. Elde edilen sonuçlara bakılarak makine öğrenimi algoritmasında sadece Sentinel-1 verileri kullanılarak düşük doğruluk elde edilmiştir. Diğer taraftan, Sentinel-1 ve Landsat-8 verileri birleştirildiğinde daha kısa sürede ve daha yüksek doğruluk elde edilmiştir.

Demarez ve ark. (2019) Fransa'nın güneybatısında bulunan mısır mahsullerini sınıflandırmak için Sentinel-1 ve Landsat-8 zaman serisi verilerinden faydalanmıştır. Elde edilen veriler makine öğrenme tekniği olan RF yöntemiyle sınıflandırılmıştır. Sentinel-1 ve Landsat-8 verilerinin birlikte kullanılarak elde edilen sayısal değerlerden veri seti oluşturulmuş ve sulanan mahsullerin sınıflandırılmasında iyi performans ($k = 0.89$) elde edilmiştir. Sentinel-1 ve Landsat-8 verilerinin ayrı ayrı test edildiğinde ($k = 0.84$) daha düşük performans elde edilmiştir. Elde edilen sonuçlara bakılarak hem radar hem de optik görüntüleri birlikte kullanılarak otlaklar, mısır, kanola, şeker pancarı ve patates gibi mahsul sınıflandırmasında daha doğru sonuçlar elde edildiğini tespit etmişlerdir.

Chen ve ark. (2020) SVM algoritması ile birlikte Landsat-8 OLI ve çift polarize (VV + VH) Sentinel-1 SAR doku özelliklerini toplayarak bir sonuç elde etmeye çalışmışlardır. Elde edilen sonuçlara bakıldığında benek filtreli veya filtresiz Landsat-8 ve Sentinel-1'i birleştirilerek mahsul sınıflandırmasını düzelttiği ve beneklerin sayısal olarak ciddi etkileri olmadığı sonucuna varmışlardır.

Arjasakusuma ve ark. (2020) Landsat-8 ve Sentinel-1 (S1) C-bandı sentetik açıklıklı radar verilerinden faydalanarak çeltik tarım alanlarını sınıflandırmaya çalışmışlardır. Makine öğrenme yöntemlerinden RF ve Regresyon Karar Ağaçları (RDT) algoritmalarından yararlanmışlardır. Çeltik alanlarının haritalanmasında RF sınıflandırıcı modellerinden KA50'de %85,65 ve KA80'de ise %85,75 kullanıcı doğruluğu sağlarken, %91,63 üretici doğruluğu sağlamıştır. RDT sınıflandırıcısında ise yalnızca %84,83 kullanıcı doğruluğu ve %80,86 üretici doğruluğu sağlamıştır.

Önermiş olduğumuz bu çalışmada ise farklı zaman-serisi Sentinel-1 ve Landsat-8 uydu görüntüleri kullanılarak, Diyarbakır'ın Bismil ilçesine bağlı Tepe Mahallesi'ne bağlı pilot alanı üzerinde bulunan pamuk ve mısır bitkilerine ait alanların derin transformer kodlayıcı tekniği yardımıyla tespit edilmesini sağlamaktır. Yaptığımız çalışmanın literatüre katkısı;

- a. Ülkemizde tarımsal ürünlere ait ekili alanlarda devlet tarafından çiftçilere verilen teşviklerde ürün çeşidi son derece önem arz etmektedir. Bu ürünlere ait alanların manuel olarak tespiti çiftçi ödemelerinde ekonomik


olarak ciddi kayıplara yol açmaktadır. Bu nedenle uzaktan algılama ile bu ve benzeri bitki alanlarının otomatik tespiti ülke ekonomisi için büyük katkı sağlamak,

- b. Ekili pamuk ve mısır alanlarının otomatik tespitiyle bu alanlarda kullanılan su miktarını optimum hale getirmek ve böylece su israfının önüne geçebilmek,
- c. Geliştirilen bu sistemle hem tarım bakanlığına bağlı uzaktan algılama birimlerin faydalanmasını sağlamak hem de çiftçilere tarımsal rekoltenin otomatik tespitinde destek vermektir,
- d. Literatüre önerilen yöntemle farklı ürünlerin sınıflandırılabilmesine ilişkin örnek bir uygulama sağlamak.



3. MATERYAL VE YÖNTEM

Tezde uygulanan yöntem ve araştırma teknikleri bu bölümde ele alınmıştır. Önerilen çalışmaların elde edilmesi birkaç adımda gerçekleştirilmiştir. Şekil 3.1’de, bu çalışmada önerilen bitki örtüsü yansıma indeksi belirleme modeline ait sistemin blok diyagramı verilmektedir.




3.1. Çalışma Alanı

Çalışma alanı olarak pilot alanın seçilmesinde Diyarbakır Tarım Müdürlüğü'nün denetimi altında bulunan Diyarbakır'ın Bismil ilçesine bağlı Tepe Mahallesi sınırlarında 2x2 km² alanı kaplayan pamuk ve mısır tarım ürünlerinin ekili olduğu tarım arazisi çalışma için uygun olarak görülmüştür. Çalışma alanının eğimi yaklaşık olarak %2,1 ve ortalama yükseltisi 558 m'dir. Yıllık ortalama sıcaklık değeri, yaz aylarında 40 °C, kış aylarında ise -3 °C göstermektedir ve ortalama yıllık sıcaklık 25.3 °C'dir. Ortalama yıllık yağış değeri ise 362 mm'dir (URL 2021). Bu tarımsal araziye ait farklı uydu görüntüsü incelenmiş olup Google Earth üzerindeki konumunu Şekil 3.2'de gösterilmiştir.



Şekil 3.2. Çalışma alanının Google Earth'daki konumu

Şekil 3.3'de görüldüğü üzere, Google Earth görüntüsü kullanılarak çalışmamızın yapıldığı arazi ve bu araziler üzerindeki parsellemeler belirtilmiştir. Koordinatların doğru alınması için parseller renklendirilmiş olup sınır hatları belirgin hale getirilmiştir.



Şekil 3.3. Google Earth üzerinde çalışma alanının parsellenmiş görünümü

3.2. Veri toplama

Bu çalışması için Sentinel-1 ve Landsat-8 olmak üzere iki ayrı uydu görüntüleri kullanılmıştır. 2015-2021 dönemleri arasındaki mısır ve pamuk bitkilerinin gelişim aşamasından üretime kadar süren Haziran, Temmuz, Ağustos, Eylül ayların uydu görüntü indekslerinden oluşmaktadır.

3.2.1 Uydu görüntüleri tarihlerinin seçimi

Bu çalışmada çok zamanlı Sentinel-1 SAR ve Landsat-8 uydu görüntüleri kullanılmıştır. Kullanılacak uydu görüntülerinin tarihlerinin belirlenebilmesi için sınıflandırılacak tarım ürünlerinin fenolojik özelliklerini bilmek gerekmektedir. İki tarım bitkisinin ortak yetiştirme ayları olan Haziran, Temmuz, Ağustos, Eylül aylarının yansıma değerleri kullanılmıştır.

Elde edilen bulgular neticesinde çalışmada kullanılacak iki tarım mahsülü için Haziran, Temmuz, Ağustos, Eylül arasındaki ayların uydu görüntülerinin kullanılmasına karar verilmiştir. Uydu görüntüleri seçilirken Sentinel-1 ve Landsat-8'e ait olan uydu görüntülerinin tarihlerinin birbirine yakın olmasına özen gösterilmiştir. Çalışmada kullanılan uydu görüntülerinin tarihleri Çizelge 3.1'de gösterilmektedir.

Çizelge 3.1. Çalışmada kullanılan uydu görüntülerinin tarihleri

Görüntü tarihleri	Sentinel -1	Landsat-8
	VV, VH	(B1, B2, B3, B4, B5, B6, B7)
	Haziran (2015-2021)	Haziran (2015-2021)
	Temmuz (2015-2021)	Temmuz (2015-2021)
	Ağustos (2015-2021)	Ağustos (2015-2021)
	Eylül (2015-2021)	Eylül (2015-2021)

Bitki örtüsünün yansıma değerlerini elde etmek için 2016-2021 dönemlerindeki Haziran, Temmuz, Ağustos, Eylül aylarına ait Sentinel-1 uydu görüntülerinden VV-VH bantları kullanılmıştır.

Landsat-8 uydu görüntülerinin yansıma değerleri içinde ise 2016-2021 dönemlerindeki Haziran, Temmuz, Ağustos, Eylül aylarına ait B1, B2, B3, B4, B5, B6 ve B7 bantlarına ait görüntüler kullanılmıştır.

3.2.2 Google earth engine

Google Earth Engine (GEE), genel bir veri kataloğu, bilgi işlem altyapısı, jeo-uzamsal API' ler ve etkileşimli bir uygulama sunucusudur. GEE, kullanıcıların Google altyapısında depolanan coğrafi referanslı görüntüler ve vektörler üzerinde algoritmalar

çalıştırmasına olanak sağlamasının yanı sıra API, görüntüleme ve analiz için verilere uygulanabilecek bir işlev kitaplığı sağlamaktadır. Earth Engine' in genel veri kataloğu ,büyük miktarda kamuya açık görüntü ve vektör veri kümesinden oluşmaktadır (Anomin 2021).

GEE, bulut tabanlı coğrafi veri kümelerinin bilimsel incelemesini görselleştirip işlemek için yüksek performanslı bilgi işlem kaynaklarına erişimi kolaylaştıran bir UA platformudur (Gorelick ve ark. 2017). GEE, veri bolluğu ile araştırmacılara daha az malzeme ve maliyet ile araştırma yapmak için büyük imkanlar sağlamaktadır. Geçmişte büyük boyutlu uydu verilerinin ofis ortamındaki bilgisayarlarda kaydedilip işlenmesi ve analiz edilmesi gerekirken şimdi GEE' nin bulut bilişim gücü sayesinde vektör verileri bulut ortamında işlenmesine olanak tanımaktadır (Kumar ve ark 2018). GEE kullanırken piksel seçimlerinde mean, median min, max vb. farklı yöntemler bulunmaktadır. Aynı zamanda GEE aracı ile bulut oranlarının az olduğu bölgeleri seçerken kod panelinden yararlanılarak bulutluluk oranının istenildiği şekilde seçilebilmesine olanak sağlamaktadır (Mateo-García ve ark. 2018). Uzaktan algılama alanındaki gelişmelere paralel olarak araştırma yapma olanağı sunan GEE tarafından büyük uydu görüntülerini ve elde edilen verileri birleştirerek kullanıcılara önemli yarar sağlamaktadır. Çevre, iklim, arazi örtüsü, jeoloji, nüfus, hastalık ve afet gibi birçok veri seti içerdiğinden büyük verilere GEE ile kolaylıkla erişilebilmektedir (Praticò ve ark. 2021).

Landsat-8, Sentinel-1 ve Sentinel-2 verileri GEE' de mevcuttur. GEE içerisindeki veriler, kullanıcıya hazır halde sunulmaktadır ve herhangi bir ön işleme sürecinden geçirilmesi gerekmeyecek şekilde analizlerde kullanılmaktadır (Anomin 2021).

Bu çalışmada Landsat-8, Sentinel-1 verileri kullanılmıştır.

3.2.3 Sentinel-1 uydu görüntüleri – SAR (Sentetik Açıklıklı Radar)

Ücretsiz ve açık veri ulaşımını sağlayan Sentinel-1, tüm hava koşullarına uygun hava ortamı sağlayarak çözünürlük, gözlem yeteneği, planlama, veri işleme ve depolama gibi alt yapıya sahiptir. Üç modda kara üzerinde çalışan Sentinel-1, çeşitli gözlem stratejileri, tarama genişlikleri ve uzamsal çözünürlüklerle bir 5.405 GHz C-bant görüntüleyici içermektedir. İki Sentinel-1 uydusu, Eylül 2014'te fırlatılan Sentinel-1A ve Nisan 2016'da fırlatılan Sentinel-1B, ortaklaşa ekvator üzerinde 6 günlük tekrarlama döngüsü, Avrupa üzerinde 6 günlük tekrar döngüsü ve 12 günlük tekrar döngüsü sağlamaktadır (Torres ve ark. 2012).

SENTINEL-1'in C-bant SAR aktif sensörü, günün ve gecenin herhangi bir anında dünya yüzeyini gözleyerek bulut örtüsü veya aydınlatma yetersizliğinden kısıtlanmayan

dalga boylarında çalışma olanağı sağlar. Pasif optik sensörler günün aydınlatmasından yararlanırken aktif bir SAR cihazı, kendi sinyalini iletmek için Dünya yüzeyini belli bir açı ile aydınlatmaktadır. Sentinel-1 radyo spektrumunda sinyal kullandığı için atmosfer ve hava koşullarından etkilenmemektedir. Aktif bir sensör olduğundan dolayı da güneş ışığına ihtiyaç duymadan görüntü sağlayabildiğinden dolayı bu uydu görüntüsünü tercih ettik. Mikrodalga sinyallerini aktif olarak Dünya'ya iletir ve iletilen enerjinin bir kısmını yerden geri saçılma şeklinde alan SAR, geri dönen saçılımı uydu yörüngesi boyunca hareket ettirmektedir. Kısa bir süre sonra geri saçılım yankısı, cihazın anteni tarafından biraz farklı bir yerde alınıp sinyalin parlaklık genliği faz bilgisi ile birlikte, sahnenin bir görüntüsünü almak için kayıt edilmektedir. Sentinel-1 radyo spektrumunda sinyal kullandığı için atmosfer ve hava koşullarından etkilenmemektedir. Aktif bir sensör olduğundan dolayı da güneş ışığına ihtiyaç duymadan görüntü sağlayabildiğinden dolayı bu uydu görüntüsünü tercih ettik.

5.405 GHz' de iki kutuplu C-bantlı Sentetik Açıklıklı Radar (SAR) cihazından veri elde eden Sentinel-1, kalibre edilmiş, orto-düzeltilmiş bir ürün elde etmek için Sentinel-1 Araç Kutusu kullanılarak işlenen S1 Yer Aralığı Algılandı (GRD) sahnelerinden meydana gelmektedir. Günlük olarak koleksiyon güncellenmekte olup yeni veriler, kullanıma sunulduktan sonraki iki gün içinde alınmaktadır.

Bu koleksiyon tüm GRD sahnelerini içerir. Her sahnenin 3 çözünürlüğü (10, 25 veya 40 metre), 4 bant kombinasyonu (sahne polarizasyonuna karşılık gelir) ve 3 enstrüman modu bulunmaktadır. Koleksiyonun bir mozaik bağlamında kullanılması, muhtemelen homojen bir bant ve parametre kümesine kadar filtrelemeyi gerektirecektir. Her sahne, enstrümanın polarizasyon ayarlarına bağlı olarak 4 olası polarizasyon bandından 1 veya 2'sini içerir. Olası kombinasyonlar, tek bant VV veya HH ve çift bant VV+VH ve HH+HV' dir:

1. VV: tek eş polarizasyon, dikey gönderme/dikey alma
2. HH: tek eş-polarizasyon, yatay gönderme/yatay alma
3. VV + VH: çift bant çapraz polarizasyon, dikey gönderme/yatay alma
4. HH + HV: çift bant çapraz polarizasyon, yatay gönderme/dikey alma

SENTINEL-1 Sentetik Açıklıklı Radar (SAR) cihazı dört özel modda veri alabilir:

- Stripmap (SM)- Anten ışını sabit bir azimut ve yükseklik açısına işaret ederken, zemin şeridinin sürekli bir darbe dizisi ile aydınlatıldığı standart bir SAR şerit haritası görüntüleme modu.

- İnterferometrik Geniş Alan (IW)- Veriler, Aşamalı Taramalı Arazi Gözlem SAR (TOPSAR) görüntüleme tekniği kullanılarak üç alanda elde edilir. IW modunda, interferometrik çiftlerin hizalanmasını sağlamak için patlamalar geçişten geçişe senkronize edilir. IW, SENTINEL-1'in karada birincil operasyonel modudur.
- Ekstra Geniş alan (EW)- Veriler, TOPSAR görüntüleme tekniği kullanılarak beş alanda elde edilir. EW modu, uzamsal çözünürlük pahasına çok geniş alan kapsamı sağlar.
- Dalga (WV)- Veri, pist boyunca 100 km'lik düzenli aralıklarla yerleştirilmiş "vinyet" adı verilen küçük şerit harita sahnelerinden oluşmaktadır. Vinyetler, yakın menzilli bir geliş açısında bir vinyet alınırken, bir sonraki vinyet uzak menzilli bir geliş açısında elde edilerek dönüşümlü olarak meydana gelmektedir. WV, SENTINEL-1'in açık okyanus üzerinde çalışma modudur (Anomin2021).

3.2.4 Landsat

Dünya çevresini anlamaya büyük ölçüde fayda sağlayan Landsat ilk kez 1972'de yörüngeye yerleştirilmiştir. Landsat uydusu, ABD'yi karadan uzaktan algılamada dünya lideri haline getirmekle birlikte ticari katma değerli endüstri tarafından uzay tabanlı verilerin devrim niteliğinde kullanımlarını doğurdu ve bölgesel yüksek çözünürlüklü uzamsal görüntüler elde ederek yeni nesil ticari uydulara yönlendirdi (Williams 2006).

Landsat programı, yer sistemleri, edinim planlaması, veri arşivleme ve analize hazır veri ürünlerinin sağlanmasının yanı sıra bilimsel ve operasyonel araştırmalar için yüksek kaliteli ölçümlerin devamlılığını sağlamaktadır. Landsat biliminin ve uygulamalarının artmasıyla veri kalitesinde büyük ilerlemeler meydana getirmiş olup bu gelişmeler Landsat-8'in piyasaya sürülmesinden sonra hızlanmıştır (Wulder 2019). Çizelge 3.2'de Landsat uydularına ait bilgiler verilmiştir (Anonim 2018).

Çizelge 3.2. 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 - 60m
5	Landsat-5	1 Mart 1984	5 Haziran 2013	MSS, TM	30 m - 60
6	Landsat- 6	5 Ekim 1993	5 Ekim 1993	ETM	15 m – 30m
7	Landsat-7	15 Nisan 1999	Hala aktif	ETM+	15 m – 30
8	Landsat-8	11 Şubat 2013	Hala aktif	OLI, TIRS	15 m – 30m
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 karbon minerallerine ve bitkilerin içerdiği suya hassastır.
- TM-6 (Termal Kızılötesi): Isı yayan materyallere hassastır.
- TM-7 (Orta Kızılötesi): Hidroksil iyonuna ve karbonit minarellerine hassastır.
- TM-9 (Pankromatik): Mekânsal çözünürlüğü diğer bantlarına göre daha yüksektir (15m.) (Karahalil 2010).

Bu çalışmada Landsat-8 uydusuna ait görüntüler kullanıldığı için bu uydu verileri üzerinde durulmuştur.

3.2.4.1 Landsat-8

Landsat-8, Nasa ve USGS işbirliği ile oluşturulmuş olup Dünya'nın karasal ve kutupsal bölgelerinin görünür, yakın kızılötesi, kısa dalga ve termal kızılötesinde küresel orta çözünürlüklü ölçümlere ulaşmaya yardımcı olmaktadır. Yaklaşık 40 yıllık Landsat hedefini artıran Landsat-8, spektrumun mavi ve sirrus bulut algılama kısmındaki yeni spektral bantlar , iki termal bant, geliştirilmiş sensör sinyal-gürültü performansı ve radyometrik çözünürlükle ilgili gelişmeler sağlayıp gün içinde fazla sayıda görüntünün toplanmasına yardımcı olan iyileştirilmiş bir görev döngüsüne sahiptir (Roy 2014).

Bu çalışmada elektro-optik bazlı çalışan pasif algılama sistemine sahip Landsat-8 uydusuna ait görüntülerden faydalanılmıştır. Bitki örtüsü yoğunluğunun ve çeşitliliğinin belirlenmesinde önemli bir parametre olan bitki örtüsü indeksleri kullanılmıştır. Tespiti yapılması istenen ürünlerin bitki örtüsü indeksleri birbirine çok yakın olduğundan dolayı bunların ayırt edilmesi zorlaşmaktadır. Landsat-8 uydu görüntülerinin içerdiği 4. bandı kırmızı (RED), 5. bandı yakın kızıl ötesi (NIR) yansımaları içermektedir. Bitkiler yeşil

görünür ışıqla birlikte Yakın Kızılötesi (NIR) ışını da yansıtır ve böylece ürünlerin tespitini kolaylıkla yapılabilmektedir (Gündoğdu 2018).

LANDSAT-7'nin yörüngesine katılan LANDSAT-8, insan geçimi için gerekli ihtiyaçların hazırlanması, gözlemlenmesi ve açıklanmasında LANDSAT programına bilimsel veriler elde edilmesine yardımcı olmuştur. LANDSAT-8 uydusu görünür ve yakın-infrared (kızılötesi) (VNIR), kısa dalga infrared (SWIR) ve termal infrared (TIR) aralıklarında görüntü almakta olup, spektral aralığa bağlı olarak 15 ile 100 m arasında bir orta uzaysal çözünürlükten meydana gelmektedir. Çizelge 3.3'de Landsat-8 uydu görüntüsünün bantlarına ait bazı bilgiler verilmiştir (URL 2022).

Çizelge 3.3. Landsat-8 uydu görüntüsünün bantlarına ilişkin bazı bilgiler

Şerit Genişliği (km)	185	
Radyometrik Çözünürlük (bit)	8 TIR- 12	
Spektral Band (µm=mikron) (VNIR = visible and near infrared) (SWIR = shortwave infrared) (TIR = thermal infrared) (OLI = Coastal/Aerosol + VNIR + SWIR + PAN + CIRRUS)	Coastal/Aerosol VNIR SWIR PAN CIRRUS TIR	Band 1- 0.43-0.45 Band 2- 0.45-0.51 Band 3- 0.52-0.60 Band 4- 0.63-0.68 Band 5- 0.84-0.88 Band 6- 1.56-1.66 Band 7- 2.10-2.30 Band 8- 0.50-0.68 Band 9- 1.360-1.390 Band 10- 10.60-11.19 Band 11- 11.50-12.51
Yersel Çözünürlük (m) (PAN = siyah beyaz)	PAN – 15 OLI – 30 TIR-100 IR- T100	

LANDSAT-8 iki farklı cihaz taşımaktadır:

a) OLI (Operational Land Imager)

Daha önceki bantların yanında kıyı/aerosol (bir katının veya bir sıvının gaz ortamı içerisinde dağılması) çalışmaları için derin mavi bandı, sirrus bulutlarının tespiti için kısa dalga infrared bandı ve kalite değerlendirme bandını kapsamaktadır.

Yeni iki spektral band Coastal/Aerosol ve kısa dalga infrared CIRRUS bandları ile yüksek ve ince bulutları tespit etmesine ve su kalitesinin ölçülmesine olanak sağlayacaktır.

OLI, dokuz adet spektral band (Coastal/Aerosol + VNIR + SWIR + PAN + CIRRUS) olarak veri toplamaktadır. Bu 9 bandın 7' si daha önceki LANDSAT-5 TM ve 7 ETM sensörlerinde bulunan aralıklarına sahiptir ki böylece eski Landsat verileri ile uyumlu olması sağlanmıştır (URL 2022).

Bu çalışmada konumsal çözünürlüğü 30 metre olan Bant 1, Bant 2, Bant 3, Bant 4, Bant 5, Bant 6 ve Bant 7 bantları kullanılmıştır. Landsat-8 OLI uydu görüntüsüne ilişkin bazı bilgiler Çizelge 3.4 ve Çizelge 3.5’de verilmiştir (Güverçin 2022).

Çizelge 3.4. Landsat-8 OLI uydu görüntüsüne ilişkin genel bilgiler

Uydu Görüntüsü Adı	Veri Tipi	Path	Row	Görüntü Tarihi	Görüntü Saati	Bulutluluk (%)	Güneş Geliş Açısı	Güneş Yüksekliği
Landsat-8 OLI	L1TP	176	35	10.09.2015	08:22	8,95	144,33706240	53,82906661

Çizelge 3.5. Landsat-8 OLI uydu görüntüsünün bantlarına ilişkin bazı bilgiler

	Bantlar	Dalga boyu (nm)	Çözünürlük(metre)
Landsat-8 OLI	Band1 -Kıyı/ Aerosol	0,43 – 0,45	30
	Bant 2(Mavi)	0,45-0,51	30
	Bant 3(Yeşil)	0,53-0,59	30
	Bant 4 (Kırmızı)	0,64-0,67	30
	Bant 5 (kızılötesi)	0,85-0,88	30
	Bant 6 (Orta kızılötesi)	1,57-1,65	30
	Bant 7 (Termal kızılötesi)	2,11-2,29	30
	Bant8 (Siyah-beyaz)	0,50-0,68	15
	Bant 9 – Sırrus	1,36 – 1,39	30
	Bant 10 (Uzan Dalga Boyu kızılötesi)	10,60-11,19	100
	Bant 11 (Uzan Dalga Boyu kızılötesi)	11,50-12,,51	100

b) TIRS (Thermal Infrared Sensor)

TIRS sensörü iki adet termal banda sahiptir. Bu sensörler sinyal-gürültü radyometrik performansı 12 bit üzerinde radyometrik çözünürlük sağlamaktadır.

Ürünler 16 bit olarak teslim edilmektedir. TIRS verisi, radyometrik, geometrik ve arazi düzeltmeli 12 bit LANDSAT-8 verisi üretilebilmesi için OLI verisine uygun kayıt edilmiştir.

Diğer LANDSAT uydularıyla veri devamı için sadece 10. Bant ile uygunluk sağlanabilmektedir (URL 2022).

Bu algılayıcının algıladığı bantlara ait özellikler Çizelge 3.6’da belirtilmiştir (Anomin 2017).


Çizelge 3.6. 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 2016-2021 dönemlerinin Haziran, Temmuz, Ağustos, Eylül aylarına ait görüntüler kullanılarak Sentinel-1 ve Landsat-8 uydu görüntülerinin yansıma indekslerinin elde edilmesi için çeşitli ön işlemler yapılmıştır.

İlk başta seçilen bölgedeki ürünlerin tespiti için 100 adet konum bilgilerini içeren GPS koordinatlar alınmış. Şekil 3.4’de koordinatların noktasal dağılımı gösterilmiştir.



Şekil 3.4. Google Earth çalışma alanı noktaların görünümü

Bu koordinatlar daha sonra excel formatından csv formatına dönüştürülmüştür. Dönüştürülen veriler csv formatında coğrafi bilgi sistemi programı olan QGIS.3.14.16 yazılımına işlenmiştir. Şekil 3.5’de işlenen noktaların görünümü verilmiştir. Daha sonra verilerin Earth Engine Code Editor (GEE-CE) platformuna aktarılması için QGIS programı yardımı ile shp formatına dönüştürülmüştür.




Şekil 3.5. QGIS'e aktarılan noktaların görünümü

Earth Engine Code Editor (GEE-CE) platformuna işlenen veriler Sentinel-1 ve Landsat-8 iki uydu görüntüleri için çeşitli ön işlemlerden geçirilmiştir.


3.3.1 Sentinel-1 görüntüsü ön işlemleri

Bu çalışma kapsamında kullanılan Sentinel-1' in Sentetik Açıklıklı Radarı (SAR), ortak ve çapraz polarize geri saçılım sağlayarak, mikrodalga endekslerinin hesaplanmasını sağlamaktadır. Bu çalışmada, mahsul sınıflandırmak için Sentinel-1 VV ve VH geri saçılım potansiyelini kullanılmıştır. Dahası, Sentinel-1 SAR GRD görüntüleri, termal gürültü giderme, radyometrik kalibrasyon ve arazi düzeltmesi gibi ön-işleme süreçlerinden geçirilmiştir.


İlk başta tespiti yapılacak 100 verinin QGIS.3.14.16 yazılımından alınan shp dosyası GEE-CE'deki 'assets' bölümünde 'add a proje' sekmesine eklenmiştir. GEE-CE platformunda, daha sonra 2016-2021 yılları arasındaki Haziran, Temmuz, Ağustos, Eylül aylarına ait Sentinel-1 görüntülerin yansıma değerleri yazılan kod ile hesaplanmıştır. Şekil 3.6-3.13'de 2021 döneminin Haziran, Temmuz, Ağustos ve Eylül aylarına ait Sentinel-1 uydu görüntüleri verilmiştir.



Şekil 3.6. Pilot Alana ait Haziran 2021 tarihli Sentinel-1 uydu ham görüntüsü



a) Sentinel-1 VV bandı




b) Sentinel-1 VH bandı


Şekil 3.7. Pilot alana ait Haziran 2021 tarihli Sentinel-1 VV-VH bantlarına ait görüntüler



Şekil 3.8. Pilot Alana ait Temmuz 2021 tarihli Sentinel-1 uydu ham görüntüsü



a) Sentinel-1 VV bandı




b) Sentinel-1 VH bandı


Şekil 3.9. Pilot alana ait Temmuz 2021 tarihli Sentinel-1 VV-VH bantlarına ait görüntüler



Şekil 3.10. Pilot Alana ait Ağustos 2021 tarihli Sentinel-1 uydu ham görüntüsü




a) Sentinel-1 VV bandı




b) Sentinel-1 VH bandı


Şekil 3.11. Pilot alana ait Ağustos 2021 tarihli Sentinel-1 VV-VH bantlarına ait görüntüler



Şekil 3.12. Pilot Alana ait Eylül 2021 tarihli Sentinel-1 uydu ham görüntüsü



a) Sentinel-1 VV bandı



b) Sentinel-1 VH bandı


Şekil 3.13. Pilot alana ait Eylül 2021 tarihli Sentinel-1 VV-VH bantlarına ait görüntüler

3.3.2 Landsat-8 görüntüsü ön işlemleri


Bu çalışma kapsamında kullanılacak Landsat-8 uydu görüntüsü için tespiti yapılacak 100 verinin QGIS.3.14.16 yazılımından alınan shp dosyası GEE-CE'deki 'assets' bölümünde 'add a proje' sekmesine eklenmiştir. GEE-CE platformunda, daha sonra 2016-2021 yılları arasındaki Haziran, Temmuz, Ağustos, Eylül aylarına ait Landsat-8 görüntülerin yansımaya değerleri yazılan kod ile hesaplanmıştır. Şekil 3.14-3.21'de 2021 döneminin Haziran, Temmuz, Ağustos ve Eylül aylarına ait Landsat-8 uydusu görüntüleri verilmiştir.





Şekil 3.14. Pilot alana ait Haziran 2021 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


Şekil 3.15. Haziran 2021 tarihli Landsat-8 uydusunun bantlarına ait görüntüler




Şekil 3.16. Pilot alana ait Temmuz 2021 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


Şekil 3.17. Temmuz 2021 tarihli Landsat-8 uydusunun bantlarına ait görüntüler




Şekil 3.18. Pilot alana ait Ağustos 2021 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


Şekil 3.19. Ağustos 2021 tarihli Landsat-8 uydusunun bantlarına ait görüntüler





Şekil 3.20. Pilot alana ait Eylül 2021 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

Şekil 3.21. Eylül 2021 tarihli Landsat-8 uydusunun bantlarına ait görüntüler

3.4. Özellik Çıkarımı


Türkiye bitki örtüsü ve çeşitliliği konusunda zengin bir ülke olduğu için bitkileri gözlemlemek ve tespit etmek için uzaktan algılama sistemlerinden faydalanılabilir. Bu verileri elde etmek için bitkilerin yansımaya değerleri kullanılmıştır ki bu veriler tarımsal ürünlere ilişkin özellikleri içermektedir. Yapılan çalışmada tespiti yapılacak aynı tür bitki örtüsüne sahip ürünlerin farklı tarihlere ait uydu görüntülerin yansımaya değerleri araştırılmıştır. Bu çalışmada seçilen pilot alanda ekili olan mısır ve pamuk mahsullerin yetiştirme ve hasat dönemleri baz alınarak farklı tarihlere ait uyduların yansımaya değerleri kullanılmıştır.

Tarımsal ürün olarak seçilen pamuk ve mısır yetiştirme- hasat dönemi ve uydu görüntülerinde yaydıkları klorofil yansımaya dalga boylarının piksel bazında yakınlığından kaynaklı ürünün tahmin edilme doğruluk oranı düşük olmaktadır. Yetiştirme ve hasat

dönemleri birbirine yakın olan bu tarımsal ürünleri ayırt etme güçlüğüne önüne geçmek için derin öğrenme yöntemi kullanılarak doğruluk oranı artırılmaya çalışılmıştır.

3.5. GPS Verilerinin Google Earth Engine Görüntüsüne İşlenmesi

Bu çalışmada seçilen pilot tarım alanı sınırları içerisinde alınan 100 farklı noktaya ait GPS verileri kullanılmıştır. Şekil 3.22’de alınan noktaların Google Earth çalışma alanındaki görüntüsü verilmiştir. Bu verilerin yansıma indekslerinin hesaplanabilmesi için bu noktaların Earth Engine Code Editor (GEE-CE) platformuna işlenmesi gerekmektedir.



Şekil 3.22. Google Earth çalışma alanı noktaların görünümü

Yansıma indekslerinin hesaplanabilmesi için tahmini yapılacak mahsullerin ekili oldukları araziden koordinat noktaları alınmış ve bu koordinatlara denk gelen ürünlerin bilgisi ‘excel çalışma sayfası’na aktarılmıştır. Excel dosyasının uzantısı çalışma sayfası formatından ‘virgülle ayrılmış değerler’ formatına dönüştürülmüştür. Csv formatına dönüştürülen veriler coğrafi bilgi sistemi programı olan QGIS.3.14.16 yazılımına ‘sınırlandırılmış metin katmanı’ ekle sekmesi kullanılarak işlenmiştir. Bunun sonucunda da Şekil 3.23’deki görüntü elde edilmiştir.



Şekil 3.23. QGIS ile seçilen 100 farklı GPS verisinin konum bilgilerine göre dağılımı

Daha sonra QGIS.3.14.16 yazılımından alınan shp dosyası GEE-CE'deki 'assets' bölümünde 'add a proje' sekmesinden eklenmiştir. Bunun sonucunda da GEE-CE platformunda Şekil 3.24 'deki görüntü elde edilmiştir.



Şekil 3.24. Pilot tarım alanında bulunan 100 farklı GPS verisinin konum bilgilerine göre dağılımı


3.6. Derin Öğrenme Teknikleri

Derin öğrenme yeni gibi görünse de 1950'lere dayanan uzun ve zengin bir geçmişi olup 1990'lardan beri ticari uygulamalarda başarıyla kullanılmıştır (Bengio ve ark 2017).

Makine öğrenmesi kadar eskiye dayanan derin öğrenme, donanım, veri seti ve algoritmalara yapılan iyileştirmeler ile 2010 yılından itibaren bu alanda yapılan uygulamalar artmaya başlamıştır (Chollet 2019).

Özellikle ekran kartlarında yapılan iyileştirmeler sayesinde, büyük verilerin derin öğrenme ağlarında daha kısa sürede işlenmesini sağlamıştır. Sistemik olarak yapay zekâ ve makine öğrenmesinin en altında yer alan derin öğrenme, en popüler yapay zeka yaklaşımıdır (LeCun ve ark. 2015).

Derin öğrenme ağlarının temeli yapay sinir ağlarıdır. Yapay sinir ağına ait bir yapay nöron modeli Şekil 3.25’de verilmiştir. Burada, $x_1..x_n$ girdi değerlerini $w_1..w_n$ ise her girdiye ait ağırlık değerlerini ifade etmektedir. Her girdi değeri kendisine ait olan ağırlık değeri ile çarpılır. Elde edilen sonuçlar transfer fonksiyonunda toplanarak aktivasyon fonksiyonundan geçirilir. Aktivasyon fonksiyonu, transfer fonksiyonu ile elde edilen sonucu belirli bir aralıkta sınırlı tutar (Bakshi, 2021).



Şekil 3.25. Yapay sinir ağı şeması (Bakshi, 2021)

Derin öğrenme, doğru kararlar almak için sinir ağlarını meydana getirmek ve eğitmek için başvurulan bir yöntemdir. Çıktılar elde edilmeden önce girdi verileri doğrusal olmayan bazı değişimlerden geçirilir. Bu yöntem bilgisayarın deneyimlerden öğrenmesine ve karmaşık zaman alan verileri anlamlandırılmasına olanak tanıyarak basit kavramlarla ilişkisi aracılığıyla açıklar. Kavram aşamasında, bilgisayarın daha kolay kavramlar sağlayıp karışık verilerin kavranmasına yardımcı olur (Goodfellow ve ark. 2018).

Yapay sinir ağlarına dayanan derin öğrenme geleneksel veri analizi ve makine öğrenimi yaklaşımlardan daha iyi başarı sağlamıştır (Janiesch ve ark 2021).

Literatürde, derin öğrenme kapsamında farklı yetenekler için tasarlanmış farklı mimariler bulunmaktadır. Bu çalışmamıza temel teşkil eden mimariler bu bölümde verilmiştir.


3.6.1.Otomatik kodlayıcı (Auto encoder)

Makine öğrenme yöntemlerinde, genel olarak veriler öznelilikler ile temsil edilir. Bunun en önemli nedeni, ham veri temsiline daha az veri kullanılarak sağlanmasıdır. Otomatik kodlayıcılar verinin farklı nitelikte gösterimini sağlamak için tasarlanmıştır.

İlk olarak 1980’li yıllarda Hinton ve PDP grup tarafından otomatik kodlayıcılar ileri sürülmüştür. Derin öğrenmenin 2006 yılında ilerlemesiyle makine öğreniminin popüler konularından sayılmaya başlamıştır. Derin Oto Kodlayıcı modeli uygulamada

daha az öznitelik kullanarak daha güvenilir sonuçlar elde etmeyi amaçlayan bir derin öğrenme yöntemidir. Veri setindeki öznitelik sayısını düşürerek hem doğruluk oranını hem de hızı artırmayı amaçlamaktadır (Baldi, 2011).

Şifreleme ve şifre çözme olarak iki farklı adımdan oluşan bir oto kodlayıcı, şifre adımında verilen girişi alır ve gizli katmanlarını kullanarak girişi, giriş birimlerinden daha küçük birimlerle ifade etmeye çalışır. Şifre çözme adımında ise, şifrelenmiş bilgiyi gizli katmanlarını kullanarak verilen girişi yeniden oluşturmaya çalışır (Bengio, 2009).



Şekil 3.26. Basit bir oto kodlayıcı ağ yapısı (Shin ve ark 2013)

Şekil 3.26’da basit bir oto kodlayıcı ağ yapısı gösterilmiştir. İlk adımda giriş verisi $x = [x^{(1)} x^{(2)} \dots x^{(m)}]$ giriş katmanından gizli (ara) katmana ‘kodlanır’ ve y özellik vektörü elde edilir. Bu işlem denklem 3.1’de verilmiştir.

$$y = f(x) = S(Wx + b) \quad (3.1)$$

Burada $y = [y^{(1)} y^{(2)} \dots y^{(n)}]^T$ gizli katmanda oluşan kodlanmış özellik değerini temsil etmektedir. Sırası ile m ve n giriş ve gizli katmanların düğümlerinin sayısı olup $m > n$ dir. W bir ağırlık matrisi ve b bias vektörüdür. $S(x)$ ise sigmoid fonksiyonudur ve $S(x) = 1 / (1 + e^{-x})$ şeklinde ifade edilir.

İkinci adım olarak kodlama sonucu gizli katmanda elde edilen y vektörleri için ‘kod çözme’ işlemi yapılarak çıkış katmanında z özellik vektörü elde edilir.


$$z = g(y) = S(W^T y + b') \quad (3.2)$$

Burada $z = [z^{(1)} z^{(2)} \dots z^{(m)}]^T$ kod çözme ile yeniden elde edilen vektördür ve b' sapma (bias) vektörüdür (Shin ve ark 2013).

3.6.2. Evrişimsel sinir ağı (CNN)

Evrişimsel sinir ağları (CNN), görüntü bölütleme, örüntü tanıma, saptama ve sınıflandırma işlemlerinde en çok kullanılan bir derin öğrenme modelidir (Lu ve ark 2020). Giriş katmanı, evrişim katmanı, havuzlama katmanı, tam bağlantı katmanı ve çıkış katmanı adı verilen katmanlardan oluşan Evrişimsel sinir ağı her bir evrişim katmanında özellik haritaları içerebilmektedir. Bu özellik haritaları sayesinde ağ, farklı özellikleri öğrenebilmektedir (Ari ve ark.2018).

Klasik sinir ağlarından farklı olan evrişimsel sinir ağları sınıflandırma başta olmak üzere birçok bilgisayarlı görü alanında kullanılmakta olup evrişim özellik çıkarma ve sınıflandırma katmanlarını içinde barındırmaktadır. Klasik bir CNN yapısı Şekil 3.27’de gösterilmiştir.



Şekil 3.27. Klasik bir CNN mimarisi (Britz 2015)

CNN mimarisi, Evrişim katmanı (konvolüsyon), aktivasyon fonksiyonu (ReLU) ve havuzlama (pooling) aşamalarını kapsamakta olup büyük boyutlu veriden küçük boyutlu öznitelikleri meydana getirir. Soruna göre evrişim katmanının ardışıl bağlanma derinliği değişken olabilmektedir.

Probleme özgü olarak evrişim katmanının ardışıl bağlanma derinliği değişmektedir. Sınıflandırma katmanı ise düşük boyutlu öznitelikler ile kategorilerin eşleşmesini sağlar ve genellikle tam bağlı bir yapay sinir ağı mimarisine sahiptir. Düşük boyutlu öznitelikler ile kategorilerin eşleşmesini sağlayan sınıflandırma katmanı ise genelde tam bağlı bir yapay sinir ağı modelinden oluşmaktadır.

Evrişim katmanının ilk adımında İmgenin bir maskeyle filtrelenmesine yardımcı olan konvolüsyon işlemidir (denklem 3.3). Konvolüsyon sonucunda yatay kenarlar, dikey kenarlar, açısall kenarlar, yumuşatılmış imge, keskinleştirilmiş imge gibi orijinal imgeyle aynı boyutta imge türevlerinden oluşmaktadır.

$$x_{i,j}^l = \sum_a^n \sum_b^n w_{ab} y_{(i+a)(j+b)}^{l-1} \quad (3.3)$$

Konvolüsyondan sonra evrişim katmanında aktivasyon aşaması yer almaktadır. Geleneksel sinir ağlarında sigmoid, tanjant hiperbolik gibi aktivasyon fonksiyonları kullanılırken CNN’de genellikle ReLu aktivasyon fonksiyonu (denklem 3.4) seçilmektedir. Doğrusal olmayan bu fonksiyon, imgedeki negatif değerlerin ayıklanmasına yardımcı olmaktadır.


$$y(x) = \max(0, x) \quad (3.4)$$

Havuzlama (pooling) işlemi ise evrişim katmanındaki son adımı olup çoğunlukla 2x2 lokal imge matrisi üzerinde maksimum, minimum, toplam veya Öznitelikler çıkarıldıktan sonra elde edilen düşük boyutlu imgeler sınıflandırma katmanına (tam bağlı yapay sinir ağı) iletilir. Geri yayılım yöntemi kullanarak sinir ağının çıkışında hesaplanan hata değeri kullanarak konvolüsyon filtre katsayılarının ve tam bağlı yapının katman ağırlıklarının güncel hale getirmeyi sağlamaktadır.

3.6.3. Transformer derin öğrenme mimarisi

Vaswani ve arkadaşları tarafından 2017 yılında ileri sürülen Transformer Derin Öğrenme (TDÖ) modeli, Dil çevirisi benzeri NLP (Neuro Linguistic Programming) fonksiyonlarda güncel model sunmuştur. TDÖ mimarisi, Yinelenen yapay sinir ağları (RNN) ve CNN tabanlı yaklaşımları bırakıp yalnızca dikkat sistemine odaklanmıştır. Şekil 3.28’de Temel transformer model mimarisine ait blok diyagramı verilmiştir (Vaswani ve ark 2017).

TDÖ mimarisi, kodlayıcı ve kod çözücü aracılığıyla bir diziyi başka diziyi çevirmek amacıyla kullanılan yapıdır.



Şekil 3.28. Temel transformer model mimarisi (Vaswani ve ark 2017)

Transformer algoritması, birçok öz dikkat katmanı ile ileri besleme ağ katmanından oluşan bir yapıdır. Kodlayıcıdaki iki alt katmanın haricinde bu iki alt katman arasında kodlayıcı-kod çözücü öz dikkat katmanı olan üçüncü bir alt katmandan oluşmaktadır. Bir sekanstaki öge sırasını ayırt edemeyen öz dikkat katmanı bu ayrımı yapmak için konumsal kodlama katmanından faydalanır. Bu aşamalardan sonra T Transformer modeli toplama (resudial) yapısına geçip bir işlem adımından sonra, işleme giren kısım ve işlem adımının sonucu belirli bir toplama ve normalleştirme fonksiyonu uygulanarak aktarım sağlanmış olur. Bu ilişki Gradyanların doğrudan ağırlar üzerinde akmasına imkan sağlayıp ağırların eğitime yapılmış olur. Bununla birlikte transformer bloklarının alt katmanlarında dikkatli şekilde t adıma geçilirken, t-1 dahil olmak üzere bu adıma kadar olan verilerin kaybolmadan iletilmiş olur (Zhang ve ark, 2020).

Aşağıda TDÖ mimarisinde bulunan bloklar açıklanmıştır.

3.6.3.1. Konumsal kodlama

Dizideki bir belirtecin bireysel konum verisini alan konumsal kodlama bu veriyi kendisi ile gömme belirteci gömmesini sağlar. Bu mimari, konum verisi ile belirtecin bir temsilinin öğrenmesi sağlanmış olmaktadır (Gehring ve ark 2017).

Bir modelin kendi aralarındaki ilişkiyi anlamak ve açıklamak için belirtecin bireysel konumuna ihtiyaç duyulmaktadır. Geçmiş mimariler RNN yapısını baz

aldığından RNN mimarisinin tekrarlanan yapısı sayesinde belirteç konumu bu mimarinden sağlanmaktaydı. Transformer modeli yinelenmeyen mimarilerden olduğundan modelin belirteçler arasındaki konumsal bağımlılıkları elde edilmesini sağlamak için her bir belirtecin bireysel konumunun bir başka örneğine gereksinim duyulmuştur (Leppich 2021).

3.6.3.2. Çok başlı dikkat mekanizması

Dikkat mekanizmasındaki işlemleri paralel olarak çalıştırıp sonuçları birleştiren çok başlı dikkat mekanizması, farklı ilişkilerin öğrenilmesini sağlamaya çalışmaktadır. Doğrusal dönüşümler ile girdi verisine ait niteliklerden sorgu (Q), anahtar (K) ve değer (V) matrisi meydana getirilir (Czempiel ve ark 2021).

Çıktı, sorgu, anahtar matrislerinin nokta çarpımının anahtar vektörün boyutunun köküne bölünmesiyle elde edilir. Bu işlemden sonra Softmax işlevi gerçekleştirilip değer matrisi ile çarpılır ve dikkat hesaplanır (denklem 3.5). Aşağıdaki denklem baz alınarak bu işlem sonucu elde edilmiştir. Bu nokta çarpımında kullanılan Q, K ve V tümü aynı verilerden elde edildiğinden Öz-Dikkat olarak isimlendirilir.

$$\text{Dikkat}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{d_k}\right)V \quad (3.5)$$

Girdiyi h küçük parçalara bölen Çok başlı öz dikkat (MSA), girdilere paralel olarak birkaç kez dikkat işlevi gerçekleştirir. Bunu uygulamasının sebebi, Q, K ve V'yi birçok kez yansıtmının sisteme bir bütün olarak yarar sağlamaya yardımcı olmasıdır. Böylelikle farklı konumlardaki farklı alt uzaylardan elde edilen verilere dahil olmuş olur. Bir katmandaki bütün başların çıktıları bir araya getirilip normalize edilir ve bir sonraki katman için girdi olarak ileri besleme ağı aracılığıyla işleme alınmış olur (Vaswani ve ark 2017).

3.6.3.3. Noktasal ileri besleme ağ katmanı

Artık bir bağlantı ile sarılmış, konum bazında ileri beslemeli bir katman olan son katman, her bir konuma ayrı ve aynı şekilde işlenen bir katman normalizasyonunu kapsamaktadır (Leppich 2021).

Bu ağ katmanı, dikkat katmanlarında eğitilen ağırlıkların potansiyel olarak daha zengin temsil gücüne sahip olmasının yanı sıra transformer bloğunun dikkat katmanlarına aktarılmasını da yardımcı olur (Karaca 2021).

4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Bu bölümde, GEE Code Editor (GEE-CE) platformu yardımıyla, ürünlerin yetiştirme-hasat ayları dikkate alınarak (Haziran, Temmuz, Ağustos, Eylül) 2016-2021 dönemleri arasında Sentinel-1 ve Landsat-8 uydu görüntülerinde mısır ve pamuk bitki alanlarına denk gelen yansıma değerleri hesaplanmıştır. Daha sonra derin transformer kodlayıcı mimarisi kullanılarak mısır ve pamuk bitkilerine ait alanlarının otomatik tespiti yapılmıştır.

4.1. Mısır ve Pamuk Bitkilerine Ait Yansıma Değerlerinin Hesaplanması

Bu kısımda, tespiti yapılacak mısır ve pamuk alanlarına ait 100 yersel nokta GEE-CE platformu üzerindeki ‘assets’ bölümünde ‘add a proje’ sekmesinden Sentinel-1 ve Landsat-8 uydu görüntülerine aktarılmıştır. Daha sonra, bu noktalara karşılık gelen VV, VH, B1, B2, B3, B4, B5, B6 ve B7 yansıma değerleri, derin öğrenme mimarisinde sonradan kullanılmak üzere her bir yersel nokta için hesaplanmıştır.

4.2. Derin Öğrenme Teknikleri yardımıyla Yansıma Değerlerinden Ürün Tespitine ait Bulgular

Bu bölümde, Google Earth Engine’de hesaplanan 100 noktanın farklı dönemlerdeki Sentinel-1 ve Landsat-8 uydu görüntülerinin yansıma değerleri elde edilerek derin öğrenme yöntemi ürün tespiti elde edilmeye çalışılmıştır. Çalışmada derin öğrenme mimarilerinden Derin Transformer Kodlayıcı (DTK) mimarisi kullanılmıştır. Bu mimarinin; başlık (Head) boyutu 256 ve başlık (head) sayısı 8 olarak belirlenmiştir. Geri besleme boyutu 8 ve toplamda 8 tranformer blok kullanılmıştır. Çok katmanlı algılayıcı 32 üniteden oluşturulmuştur. Bu ünitenin ezberlemesini engellemek için dropout oranı 0.4 olarak belirlenmiştir. Mimarinin, öğrenme oranı 0.001 ve kayıp fonksiyonu olarak binary_crossentropy kullanılmıştır. Mimari 128,914 eğitilebilir parametreden oluşmaktadır. Çalışmada oluşturulan veri setinin %80 oranı eğitim, %20 oranı test için kullanılmıştır. Eğitim için ayrılan verinin %10 oranı da doğrulama verisi olarak kullanılmıştır.

Performans hesabı için Şekil 4.1’de gösterilen karışıklık matrisi (Confusion Matrix)’den faydalanılmıştır.

	Öngürülen sınıf (Predicted Class)	
Gerçek Sınıf (Actual Class)	Gerçek Pozitif GP	Yanlış Negatif YN
	Yanlış Pozitif YP	Doğru Negatif GN

Şekil 4.1. Karışıklık matrisi tablosu

Karışıklık matrisi, gerçek değeri bilinen bir dizi test üzerinde, sınıflandırma modelinin performansını hesaplamak için başvurulmuş bir tablodur.

Bu matrisi tablosunda kullanılan;

Gerçek Pozitif (GP): Bunlar gerçek değeri 1 ve tahmin ettiğimiz değerin de 1 olduğu örneklerdir.

Doğru Negatif (GN): Bunlar gerçek değeri 0 ve tahmin ettiğimiz değerin de 0 olduğu örneklerdir.

Yanlış Pozitif (YP): Bunlar gerçek değeri 0 ve tahmin ettiğimiz değerin de 1 olduğu örneklerdir.

Yanlış Negatif (YN): Bunlar gerçek değeri 1 ve tahmin ettiğimiz değerin de 0 olduğu örneklerdir.

Kullanılan sınıflandırma sistemlerinin güvenilirlik hesabı için Doğruluk (Accuracy), Kesinlik (Precision), Duyarlılık (Recall), F1-Skor formülleri kullanılmıştır. Ayrıca sınıflandırıcının tüm olası değerler üzerindeki performansını özetlemek için ROC eğrisinden faydalanılmıştır.

Doğruluk (Accuracy): Sınıflandırıcının ne sıklıkla doğru tahmin ettiğinin bir ölçüsüdür. Doğru tahmin edilen örneklerin toplam tahmin edilen örneklere bölünmesi ile elde edilir.

$$\text{Doğruluk} = (GP+GN) / (GP+GN+YP+YN) \quad (4.1)$$

Kesinlik (Precision): Tüm sınıflardan, doğru olarak ne kadar tahmin edildiğinin bir göstergesidir. Doğru tahmin edilen pozitif örneklerin toplam tahmin edilen pozitif örneklere bölünmesi ile elde edilir.

$$\text{Kesinlik} = GP / (GP + YP) \quad (4.2)$$

Duyarlılık (Recall): Pozitif olarak tahmin etmemiz gereken verilerin ne kadarının pozitif olduğunu tahmin ettiğimiz göstergesidir. Doğru tahmin edilen pozitif örneklerin gerçek sınıftaki tüm örneklere bölünmesinden elde edilir.


$$\text{Duyarlılık} = GP / (GP + YN) \quad (4.3)$$

F1-Skor: Sınıflandırıcının ne kadar iyi performans gösterdiğinin bir ölçüsü olup sınıflandırıcıları karşılaştırmakta genellikle kullanılır. Bu, kesinlik ve duyarlılığın harmonik ortalamasıdır.

$$\text{F1-Skor} = 2 * (\text{Duyarlılık} * \text{Kesinlik}) / (\text{Duyarlılık} + \text{Kesinlik}) \quad (4.4)$$

Alıcı İşlem Karakteristik Eğrisi (ROC Eğrisi): Genelde sınıflandırma yapmak için oluşturduğumuz modelin güvenilir sonuçlar verip vermediğini gösteren bir


parametredir. Çizelge 4.2’de gösterilen Gerçek Pozitif Değerlerin Oranına (Hassasiyet) (x eksen) karşı Gerçek Pozitif Değerlerin Oranını (Özgünlük) (y eksen) çizerek oluşturulmaktadır. ROC Eğrisi, Hassasiyet / Özgünlük (Sensitivity / Specificity) raporu elde etmeyi sağlar. ROC eğrisinin altındaki alanın fazla olası test edilen verilerin iyi ölçümler yaptığının işaretidir. (Metz, 2006). Sol üst köşeden geçen ROC eğrisi iyi ayırt etmeyi sağlamaktadır. Bundan dolayı testin doğruluğu ROC eğrisinin sol üst köşeye yaklaştıkça artmaktadır (Zweig ve ark,1993). Şekil 4.2’de ROC eğrisi grafiği verilmiştir.



Şekil 4.2. ROC eğrisi grafiği


4.2.1. Sentinel-1 yansıma değerleri ve DTK yaklaşımından hesaplanan performans metrikleri

Bu bölümde, 2016-2021 yıllarının Haziran, Temmuz, Ağustos, Eylül ayları arasındaki pamuk ve mısır ürünlerine ait Sentinel-1 VV ve VH yansıma değerleri kullanılmış ve derin transformer kodlayıcı mimarisi yardımıyla bu ürünlere ait alanlar tespit edilmiştir. Şekil 4.3’de sınıflandırma yöntemine ait karışıklık matrisi tablosu ve Şekil 4.4’de ROC eğrisi grafiği verilmiştir. Ayrıca performans metrikleri Çizelge 4.1’de sunulmuştur.



Şekil 4.3. Sentinel-1'e ait yansımalar ve DTK yaklaşımına ait karışıklık matrisi tablosu

Sentinel-1 yansımalar ve TDK yaklaşımında test için 6 adet pamuk ve 14 adet mısır verisi kullanılmıştır. Bu veriden 4 adet pamuk ve 13 adet mısır verisi doğru sınıflandırılmıştır. Diğer taraftan, 2 adet mısır ve bir adet pamuk verisi yanlış sınıflandırılmıştır.



Şekil 4.4. Sentinel-1'e ait yansımalar ve DTK yaklaşımına ait ROC eğrisi grafiği


Çizelge 4.1. Sentinel-1'e ait yansımalar ve DTK yaklaşımına ait performans metrikleri

Sınıf	Kesinlik	Duyarlılık	f1-Skor
Pamuk (0)	0.80	0.67	0.73
Mısır (1)	0.87	0.93	0.90
Makro Ortalama	0.83	0.80	0.81
Ağırlık Ortalama	0.85	0.85	0.85

Sentinel-1 uydu görüntülerinin yansımalar değerleri kullanılarak Performans metrikleri incelendiğinde en iyi kesinlik, duyarlılık ve f1-Skor değeri mısır verisinden elde edilmiş olup, %85 doğruluk gözlemlenmiştir.


4.2.2. Landsat-8 yansımaya değerleri ve DTK yaklaşımından hesaplanan performans metrikleri

Bu kısımda, 2016-2021 yıllarının Haziran, Temmuz, Ağustos, Eylül ayları arasındaki pamuk ve mısır ürünlerine ait Landsat-8'in B1, B2, B3, B4, B5, B6 ve B7 band parametreleri kullanılmış ve derin transformer kodlayıcı mimarisi yardımıyla bu ürünlere ait alanlar tespit edilmiştir. Şekil 4.5'de sınıflandırma yöntemine ait karışıklık matrisi tablosu ve Şekil 4.6'da ROC eğrisi grafiği verilmiştir. Ayrıca performans metrikleri Çizelge 4.2'de sunulmuştur.



Şekil 4.5. Landsat-8'e ait yansımaya değerleri ve DTK yaklaşımına ait karışıklık matrisi tablosu

Landsat-8 yansımaya değerleri ve DTK Yaklaşımında test için 6 adet pamuk ve 14 adet mısır verisi kullanılmıştır. Bu veriden 6 adet pamuk ve 13 adet mısır verisi doğru sınıflandırılmıştır. Diğer taraftan, 1 adet mısır verisi yanlış sınıflandırılmıştır.



Şekil 4.6. Landsat-8'e ait yansımaya değerleri ve DTK yaklaşımına ait ROC eğrisi grafiği


Çizelge 4.2. Landsat-8'e ait yansımaya değerleri ve DTK yaklaşımına ait performans metrikleri

Sınıf	Kesinlik	Duyarlılık	f1-Skor
Pamuk (0)	0.86	1.00	0.92
Mısır (1)	1.00	0.93	0.96
Makro Ortalama	0.93	0.96	0.94
Ağırlık Ortalama	0.96	0.95	0.95

Landsat-8 uydu görüntülerinin yansımaya değerleri kullanılarak performans metrikleri incelendiğinde en iyi kesinlik ve f1-Skor değeri mısır verisinden elde edilirken, en iyi duyarlılık pamuk verisinden elde edilmiş olup %95 doğruluk gözlemlenmiştir.


4.2.3. Sentinel-1 ve Landsat-8 yansımaya değerleri ve DTK yaklaşımından hesaplanan performans metrikleri

Bu bölümde, 2016-2021 yıllarının Haziran, Temmuz, Ağustos, Eylül ayları arasındaki pamuk ve mısır ürünlerine ait Sentinel-1 (VV, VH) ve Landsat-8 (B1, B2, B3, B4, B5, B6, B7) band parametreleri kullanılarak derin transformer kodlayıcı mimarisi yardımıyla bu ürünlere ait alanlar tespit edilmiştir. Şekil 4.7'de sınıflandırma yöntemine ait karışıklık matrisi tablosu ve Şekil 4.8'de ROC eğrisi grafiği verilmiştir. Ayrıca performans metrikleri Çizelge 4.3'de sunulmuştur.



Şekil 4. 7. Sentinel-1 ve Landsat-8'e ait yansımaya değerleri ve DTK yaklaşımına ait karışıklık matrisi tablosu

Sentinel-1 ve Landsat-8 yansımaya değerleri ve DTK Yaklaşımında test için 9 adet pamuk ve 31 adet mısır verisi kullanılmıştır. Bu veriden 4 adet pamuk ve 31 adet mısır verisi doğru sınıflandırılmıştır. Diğer taraftan, 5 adet mısır verisi yanlış sınıflandırılmıştır.



Şekil 4.8. Sentinel-1 ve Landsat-8'e ait yansımalar ve DTK yaklaşımına ait ROC eğrisi grafiği

Çizelge 4.3. Sentinel-1 ve Landsat-8'e ait yansımalar ve DTK yaklaşımına ait performans metrikleri

Sınıf	Kesinlik	Duyarlılık	f1-Skor
Pamuk (0)	1.00	0.44	0.62
Mısır (1)	0.86	1.00	0.93
Makro Ortalama	0.93	0.72	0.77
Ağırlık Ortalama	0.89	0.88	0.86

Son olarak Sentinel-1 ve Landsat-8 uydu görüntülerinin yansımalar ve DTK yaklaşımına ait performans metrikleri incelendiğinde en iyi kesinlik değeri pamuk verisinden elde edilirken, en iyi duyarlılık ve f1-Skor değeri mısır verisinden elde edilmiş olup %87.5 doğruluk gözlemlenmiştir.

4.3. Bulguların Değerlendirilmesi

Bu çalışmada üç farklı veri seti kullanılarak derin öğrenme modellerinden DTK modeli veri seti performans metrikleri karşılaştırılmıştır.

Çizelge 4.4. Çalışmada üç farklı gruba ait DTK yaklaşımından elde edilen sonuçların karşılaştırılması

Uydu Görüntüsü	Sentinel-1	Landsat-8	Sentinel-1 ve Landsat-8
Kesinlik (Pamuk)	0.80	0.86	1.00
Kesinlik (Mısır)	0.87	1.00	0.86
Kesinlik (Makro ortalama)	0.83	0.93	0.93
Kesinlik (Ağırlık ortalama)	0.85	0.96	0.89
Duyarlılık (Pamuk)	0.67	1.00	0.44
Duyarlılık (Mısır)	0.93	0.93	1.00
Duyarlılık (Makro ortalama)	0.80	0.96	0.72
Duyarlılık (Ağırlık ortalama)	0.85	0.95	0.88
F 1-Skor (Pamuk)	0.73	0.92	0.62
F 1-Skor (Mısır)	0.90	0.96	0.93
F 1-Skor (Makro ortalama)	0.81	0.94	0.77
F 1-Skor (Ağırlık ortalama)	0.85	0.95	0.86
Doğruluk	85	95	87.5

Tablodaki sonuçlar incelendiğinde ürün tahmininde en düşük doğruluk Sentinel-1 (VV, VH) uydu görüntüsünün yansımaya değerlerinden %85 sınıflandırma doğruluğu elde edilirken, Landsat-8 (B1, B2, B3, B4, B5, B6, B7) band parametreleri kullanılarak %95 elde edilmiştir. Pamuk ve mısır ürünlerine ait Sentinel-1 (VV, VH) ve Landsat-8 (B1, B2, B3, B4, B5, B6, B7) band parametreleri kullanılarak derin transformer kodlayıcı mimarisi yardımıyla bu ürünler %87,5 doğruluk oranı ile sınıflandırılmıştır.

Çalışmaya ait sonuçlara bakıldığında en yüksek performans değerine %95 doğruluk değeriyle Landsat-8 band parametreleri kullanılarak ulaşılmıştır. Bunun sebebi Landsat-8 bandlarının farklı tarımsal bitkilerde farklı yansımaya değerleri oluşturması ve bu yansımaya değerleriyle tarımsal ürünlerin tespitinde daha iyi sonuçlar sağlaması olarak düşünülmektedir.

Çizelge 4.5. Literatürdeki benzer çalışmalara ait performans değerlerinin karşılaştırmalı tablosu

Kaynak	Tarımsal Ürün	Sensör	Yöntem	Doğruluk (%)
Schultz ve ark. (2015)	Şeker Kamışı, Soya Fasulyesi, Manyok, Fıstık ve Diğerleri	Landsat-8	RF	80
Mulyono ve ark. (2016)	Şeker Kamışı	Landsat-8	SVM	90,78
Zhou ve ark. (2017)	Fıstık	Landsat-8	CNN	96,42
Acar ve ark. (2021)	Buğday, Mercimek	Landsat-8	SVM	83,30
Crisóstomo ve ark. (2020)	Pirinç	Sentinel-1	RNN	98,00
Son ve ark. (2021)	Pirinç	Sentinel-1	DT ve RF	96,3 ve 96,6
Lin ve ark. (2022)	Pirinç	Sentinel-1	LSTM-MTL	98,3
Fonteh ve ark. (2016)	Yerleşim, Su, Mangrovlar ve Diğer Bitki Örtüsü ve Kauçuk	Landsat-8, Sentinel-1	SVM	91,96
Demarez ve ark. (2019)	Mısır	Landsat-8, Sentinel-1	RF	89
Arjasakusuma ve ark. (2020)	Çeltik	Landsat-8, Sentinel-1	RF	91,63
Önerilen Yaklaşım	Mısır, Pamuk	Landsat-8, Sentinel-1	Derin Transformer Kodlayıcı	95

Çizelge 4.5'deki benzer çalışmalara ait sonuçlar ele alındığında, önerilen çalışmamızdan elde edilen %95 doğruluk tüm benzer çalışmalar arasındaki en yüksek değerlerden birini teşkil etmektedir.

5. SONUÇLAR VE ÖNERİLER

Son zamanlarda, uzaktan algılama teknolojileri derin öğrenme mimarileriyle birlikte kullanıldığında birçok alanda olduğu gibi tarımsal ürünlerin tespiti, gelişimi ve rekolte tahmini gibi uygulamalarda da başarılı sonuçlar vermektedir.

Bu çalışmada aktif algılama sistemine sahip ortak ve çapraz polarizasyonlu geri saçılım sağlayarak mikrodalga endekslerinin hesaplanmasını sağlayan Sentinel-1 uydu görüntüsü ile pasif algılama sistemine sahip elektro-optik bazlı çalışan Landsat-8 uydusuna ait görüntüler kullanılmıştır. Bu görüntülerin yansıma değerleri daha sonra hesaplanmış ve derin öğrenme yöntemlerinden DTK modeli yardımıyla mısır ve pamuk bitkilerine ait ürünlerin tarımsal tespiti yapılmıştır.

Önerilen çalışma birkaç aşamadan oluşmaktadır. İlk aşamada tespiti yapılması istenen ürünler belirlenmiş olup bu ürünlerin olduğu çalışma alanı belirlenmiştir. Belirlenen çalışma alanında ürün tespiti için 100 adet noktaya ait konumun GPS koordinatları alınmıştır. Alınan koordinatlara ait ürünlerin türleri belirlenerek veri seti oluşturulmuş ve bu veri setleri derin öğrenme yaklaşımlarından DTK mimarisi kullanılarak bu ürünlere ait tarımsal alanlar belirlenmiştir. Her bir yaklaşıma ait performans hesaplamaları için karışıklık matrisleri oluşturulmuş ve bu matrislerden farklı istatistiksel metrikler (kesinlik, duyarlılık, F1 Skoru ve doğruluk) hesaplanmıştır.

Sonuç olarak bu çalışmada elde edilen verilerden oluşturulan üç gruba ait veri setinden derin öğrenme yaklaşımı ile ürün tespiti doğruluk oranı elde edilmiştir. Bu gruplar içerisinde elde edilen DTK yaklaşımına ait sonuçlar incelendiğinde Landsat-8 uydu görüntüsünden elde edilen sonuçların diğer gruplara göre daha yüksek doğruluk oranına sahip olduğu görülmüştür.

Yapılan çalışmaların devamı olarak daha çok tarımsal ürün tespiti için farklı uydu görüntülerinin yansıma değerleri kullanarak farklı derin öğrenme mimarilerinden tarımsal alanlardaki mahsullerin tespiti amaçlanmaktadır.

KAYNAKLAR

- Acar, E. & Altun, M. (2021). Classification of the Agricultural Crops Using Landsat-8 NDVI Parameters by Support Vector Machine. *Balkan Journal of Electrical and Computer Engineering*, 9 (1), 78-82. DOI: 10.17694/bajece.863147
- Anomin, (2021). ESA. Erişim: [<https://sentinel.esa.int/web/sentinel/user-guides>], Erişim Tarihi 25.01.2021
- Anomin, (2021). Get Started with Earth Engine Erişim: [<https://developers.google.com/earth-engine/guides/getstarted>], Erişim Tarihi:05.03.2021.
- Ari A. ve Hanbay D.2018, Deep learning based brain tumor classification and detection system, *Turkish J. Elect. Eng. Comput. Sci.*, 26: 2275–2286
- Arjasakusuma, S., Swahyu Kusuma, S., Rafif, R., Saringatin, S., & Wicaksono, P. (2020). Combination of Landsat 8 OLI and Sentinel-1 SAR Time-Series Data for Mapping Paddy Fields in Parts of West and Central Java Provinces, Indonesia. *ISPRS International Journal of Geo-Information*, 9(11), 663.
- Bakshi, A .2021, Deep Learnin Tutorial: Artifical intelligence using deep learning. Edureka [https://www.edureka.co/blog/deep-learning-tutorial#disqus_thread]. Erişim Tarihi: 25.05.2021
- Baldi, P. (2011). Autoencoders, unsupervised learning and deep architectures. In *Proceedings of the 2011 International Conference on Unsupervised and Transfer Learning Workshop- Volume 27* (pp. 37–50).
- Bengio, Y. (2009). Learning Deep Architectures for AI. *Found. Trends Mach. Learn.*, 2(1), 1–127.
- Bengio, Y., Goodfellow, I., & Courville, A. (2017). *Deep learning* (Vol. 1). Cambridge, MA, USA: MIT press.11-17
- Britz Denny, (2015), Understanding convolutional neural networks for nlp, Investigation Of Deep Learning Approaches For Biomedical Data Classification. Erişim Tarihi:28.07.2022
- Chen, S., Useya, J., & Mugiyo, H. (2020). Decision-level fusion of Sentinel-1 SAR and Landsat 8 OLI texture features for crop discrimination and classification: case of Masvingo, Zimbabwe. *Heliyon*, 6(11), e05358.
- Chollet, F., 2019, *Python ile Derin Öğrenme*, Buzdağı Yayınevi, Ankara, ISBN: 978-605-69024-2-0.
- Crisóstomo de Castro Filho, H., Abílio de Carvalho Júnior, O., Ferreira de Carvalho, O. L., Pozzobon de Bem, P., dos Santos de Moura, R., Olino de Albuquerque, A., ... & Trancoso Gomes, R. A. (2020). Rice crop detection using LSTM, Bi-LSTM, and machine learning models from sentinel-1 time series. *Remote Sensing*, 12(16), 2655.

- Czempiel, T., Paschali, M., Ostler, D., Kim, S. T., Busam, B., & Navab, N. (2021). OperA: Attentionregularized transformers for surgical phase recognition, arXiv:2103.03873, 2
- Demarez, V., Helen, F., Marais-Sicre, C., & Baup, F. (2019). In-season mapping of irrigated crops using Landsat 8 and Sentinel-1 time series. *Remote sensing*, 11(2), 118.
- Demarez, V., Helen, F., Marais-Sicre, C., & Baup, F. (2019). In-season mapping of irrigated crops using Landsat 8 and Sentinel-1 time series. *Remote sensing*, 11(2), 118.
- Fonteh, M. L., Theophile, F., Cornelius, M. L., Main, R., Ramoelo, A., & Cho, M. A. (2016). Assessing the utility of Sentinel-1 C band synthetic aperture radar imagery for land use land cover classification in a tropical coastal systems when compared with Landsat 8. *Journal of Geographic Information System*, 8(04), 495.
- Gao, H., Wang, C., Wang, G., Li, Q., & Zhu, J. (2019). A new crop classification method based on the time-varying feature curves of time series dual-polarization Sentinel-1 data sets. *IEEE Geoscience and Remote Sensing Letters*, 17(7), 1183-1187.
- Gehring, J., Auli, M., Grangier, D., Yarats, D. ve YN Dauphin. YN., (2017) “Convolutional Öğrenmeyi sıraya dizmek”, Uluslararası Makine Öğrenimi Konferansı'nda, 1243–1252, PMLR, 2017.
- Gilbertson, J. K., Kemp, J., & Van Niekerk, A. (2017). Effect of pan-sharpening multi-temporal Landsat 8 imagery for crop type differentiation using different classification techniques. *Computers and Electronics in Agriculture*, 134, 151-159.
- Goodfellow, I. Bengio, Y. and Courville, A., 2018 *Derin Öğrenme*, (Çev: F. Y. Vural, R. G. Cinbiş, S. Kalkan), Buzdağı Yayınevi
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., & Moore, R. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote sensing of Environment*, 202, 18-27.
- Gündoğdu K (2018). Buğday Ekili Parsellerde NDVI Değerlerinin Konumsal ve Zamana Bağlı Değişiminin Belirlenmesi. *KSÜ Tarım ve Doğa Dergisi*, 21(4), 492 - 499.
- Güvercin, İ., (2022). Saf kızılçam meşcerelerinde sentinel-1a ve landsat-8 olı uydu görüntüsü kullanılarak topraküstü biyokütlenin tahmin edilmesi (anamur orman işletme şefliği örneği), Yök tez
- Huang, Y., Chen, Z. X., Tao, Y. U., Huang, X. Z., & Gu, X. F. (2018). Agricultural remote sensing big data: Management and applications. *Journal of Integrative Agriculture*, 17(9), 1915-1931.
- Ikasari, I. H., Ayumi, V., Fanany, M. I., & Mulyono, S. (2016, October). Multiple regularizations deep learning for paddy growth stages classification from

- LANDSAT-8. In 2016 International Conference on Advanced Computer Science and Information Systems (ICACSIS) (pp. 512-517). IEEE.
- Jamali, A. (2020). Land use land cover mapping using advanced machine learning classifiers: A case study of Shiraz city, Iran. *Earth Science Informatics*, 13(4), 1015-1030.
- Janiesch, C., Zschech, P. & Heinrich, K. (2021) Machine learning and deep learning <https://link.springer.com/article/10.1007/s12525-021-00475-2#citeas> Erişim Tarihi: 10.06.2021
- Karabulut,E.,M.(2016), Investigation Of Deep Learning Approaches For Biomedical Data Classification, Çukurova University, Doktora Tezi, 2016.
- Karaca.A.,2021. Derin öğrenme ile türkçe haber metinlerine başlık üretme sayfa 24. Erişim adresi: <https://dspace.trakya.edu.tr/xmlui/handle/trakya/5304>
- Karahalil,U., (2010) Orman kaynaklarının planlanmasında uygu görüntülerinin kullanılması. Erişim: [https://www.ktu.edu.tr/dosyalar/15_01_03_7b7bc.pdf], Erişim Tarihi 25.03.2021.
- Kerr, J. T., & Ostrovsky, M. (2003). From space to species: ecological applications for remote sensing. *Trends in ecology & evolution*, 18(6), 299-305.
- Kumar, L., & Mutanga, O. (2018). Google Earth Engine applications since inception: Usage, trends, and potential. *Remote Sensing*, 10(10), 1509.
- Leppich, R. (2021). Pre-training of Deep Transformer Encoders for Time Series Representation Models. 10.13140/RG.2.2.18298.82882.
- Lin, Z., Zhong, R., Xiong, X., Guo, C., Xu, J., Zhu, Y., ... & Lin, T. (2022). Large-Scale Rice Mapping Using Multi-Task Spatiotemporal Deep Learning and Sentinel-1 SAR Time Series. *Remote Sensing*, 14(3), 699.
- Lu, Z., Bai, Y., Chen, Y., Su, C., Lu, S., Zhan, T., Hong, X., Wang, S. (2020). The classification of gliomas based on a pyramid dilated convolution resnet model. *Pattern Recognition Letters*, 133, 173-179.
- Mateo-García, G., Gómez-Chova, L., Amorós-López, J., Muñoz-Marí, J., & Camps-Valls, G. (2018). Multitemporal cloud masking in the Google Earth Engine. *Remote Sensing*, 10(7), 1079.
- METZ, C. E. (2006). Receiver Operating Characteristic Analysis: A Tool For The Quantitative Evaluation Of Observer Performance And Imaging Systems. *Journal Of The American College Of Radiology*, 3(6), 413-422.
- Mulyono, S. (2016, November). Identifying sugarcane plantation using LANDSAT-8 images with support vector machines. In *IOP Conference Series: Earth and Environmental Science* (Vol. 47, No. 1, p. 012008). IOP Publishing.

- Ndikumana, E., Ho Tong Minh, D., Baghdadi, N., Courault, D., & Hossard, L. (2018). Deep recurrent neural network for agricultural classification using multitemporal SAR Sentinel-1 for Camargue, France. *Remote Sensing*, 10(8), 1217.
- Pareeth, S., Karimi, P., Shafiei, M., & De Fraiture, C. (2019). Mapping agricultural landuse patterns from time series of Landsat 8 using random forest based hierarchial approach. *Remote Sensing*, 11(5), 601.
- Praticò, S., Solano, F., Di Fazio, S., & Modica, G. (2021). Machine learning classification of mediterranean forest habitats in google earth engine based on seasonal sentinel-2 time-series and input image composition optimisation. *Remote Sensing*, 13(4), 586.
- Qu, Y., Zhao, W., Yuan, Z., & Chen, J. (2020). Crop mapping from sentinel-1 polarimetric time-series with a deep neural network. *Remote Sensing*, 12(15), 2493.
- Roy, D. P., Wulder, M. A., Loveland, T. R., Woodcock, C. E., Allen, R. G., Anderson, M. C., ... & Zhu, Z. (2014). Landsat-8: Science and product vision for terrestrial global change research. *Remote sensing of Environment*, 145, 154-172.
- Schultz, B., Immitzer, M., Roberto Formaggio, A., Del'Arco Sanches, I., José Barreto Luiz, A., & Atzberger, C. (2015). Self-guided segmentation and classification of multi-temporal Landsat 8 images for crop type mapping in Southeastern Brazil. *Remote Sensing*, 7(11), 14482-14508.
- Shimizu, K., Ota, T., & Mizoue, N. (2019). Detecting forest changes using dense Landsat 8 and Sentinel-1 time series data in tropical seasonal forests. *Remote Sensing*, 11(16), 1899.
- Shin, H.C.; Orton, M.R.; Collins, D.J.; Doran, S.J.; Leach, (2013), Stacked autoencoders for unsupervised feature learning and multiple organ detection in a pilot study using 4d patient data. *IEEE Trans. Pattern Anal. Mach. Intell.* 35, 1930–43.
- Singh, M., & Tyagi, K. D. (2021). Pixel based classification for Landsat 8 OLI multispectral satellite images using deep learning neural network. *Remote Sensing Applications: Society and Environment*, 24, 100645.
- Son, N. T., Chen, C. F., Chen, C. R., Toscano, P., Cheng, Y. S., Guo, H. Y., & Syu, C. H. (2021). A phenological object-based approach for rice crop classification using time-series Sentinel-1 Synthetic Aperture Radar (SAR) data in Taiwan. *International Journal of Remote Sensing*, 42(7), 2722-2739.
- Teke, M., Deveci, H. S., Öztoprak, F., Efendioğlu, M., Küpçü, R., Demirkesen, C., ... & Demirpolat, C. (2016) Akıllı tarım fizibilite projesi: hassas tarım uygulamaları için havadan ve yerden veri toplanması, işlenmesi ve analizi
- Torres, R., Snoeij, P., Geudtner, D., Bibby, D., Davidson, M., Attema, E., ... & Rostan, F. (2012). GMES Sentinel-1 mission. *Remote sensing of environment*, 120, 9-24.

- URL, (2021). [<https://www.mgm.gov.tr/>], Erişim Tarihi: 3 Mart 2021
- URL, (2022). [<https://wiki.netcad.com.tr/pages/viewpage.action?pageId=217386563>], Erişim Tarihi: 15 Nisan 2022
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Polosukhin, I. (2017). Attention is all you need. *Advances in neural information processing systems*
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., ... & Polosukhin, I. (2017). Attention is all you need. *Advances in neural information processing systems*, 30.
- Wei, P., Chai, D., Lin, T., Tang, C., Du, M., & Huang, J. (2021). Large-scale rice mapping under different years based on time-series Sentinel-1 images using deep semantic segmentation model. *ISPRS journal of photogrammetry and remote sensing*, 174, 198-214.
- Williams, DL, Goward, S. ve Arvidson, T. (2006). Landsat. *Fotogrametrik Mühendislik ve Uzaktan Algılama*, 72 (10), 1171-1178.
- Wójtowicz, M., Wójtowicz, A., & Piekarczyk, J. (2016). Application of remote sensing methods in agriculture. *Communications in Biometry and Crop Science*, 11(1), 31-50.
- Wulder, M. A., Loveland, T. R., Roy, D. P., Crawford, C. J., Masek, J. G., Woodcock, C. E., ... & Zhu, Z. (2019). Current status of Landsat program, science, and applications. *Remote sensing of environment*, 225, 127-147.
- Xu, L., Zhang, H., Wang, C., Zhang, B., & Liu, M. (2018). Crop classification based on temporal information using sentinel-1 SAR time-series data. *Remote Sensing*, 11(1), 53.
- Y. LeCun, Y. Bengio ve G. Hinton, (2015), Deep learning, *Nature*, cilt 521, pp. 436-444, 2015.
- Zhang, A., Lipton, Z.C., Li, M. & Smola, A.J. (2020). Dive into Deep Learning. Erişim adresi: <https://d2l.ai/d2l-en.pdf> sayfa 426-427
- Zhang, M., Lin, H., Wang, G., Sun, H., & Fu, J. (2018). Mapping paddy rice using a convolutional neural network (CNN) with Landsat 8 datasets in the Dongting Lake Area, China. *Remote Sensing*, 10(11), 1840.
- Zhou, Z., & Li, S. (2017, November). Peanut planting area change monitoring from remote sensing images based on deep learning. In *2017 4th International Conference on Systems and Informatics (ICSAI)* (pp. 1358-1362). IEEE.
- Zweig, M. H., & Campbell, G. (1993). Receiver-operating characteristic (ROC) plots: a fundamental evaluation tool in clinical medicine. *Clinical chemistry*, 39(4), 561-577.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Reyhan ŞİMŞEK BAĞCI
Uyruğu : T.C

EĞİTİM

Derece	Adı	Bitirme Yılı
Lise	: Yunus Emre Lisesi Merkez/DİYARBAKIR	2009
Üniversite	: Fırat Üniversitesi Merkez/ELAZIĞ	2013
Yüksek Lisans	: Batman Üniversitesi Merkez/BATMAN	2022
Doktora	:	

İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
2013	CMD Yapi	Proje Kontrol
2015	YDA	İSG Uzmanı
2016	İnser Mühenslik	Proje Kontrol
2019	Silvan MTAL	Öğretmen
2022	Prof.Dr.Necmettin Erbakan MTAL	Öğretmen

UZMANLIK ALANI: Elektrik Tesisleri

YABANCI DİLLER: İngilizce

BELİRTMEK İSTEĞİNİZ DİĞER ÖZELLİKLER

YAYINLAR: Sentinel-1 Uydu Görüntü İndeksleri Kullanılarak Tarımsal Ürünlerin Derin Öğrenme Yöntemleri İle Tespiti