

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



**KURAKLIK GIDA VE SU GÜVENLİĞİ İÇİN UYDU
VERİLERİNİ KULLANAN AKILLI TARIM VERİ ANALİZİ
YAKLAŞIMI**

Serhat ATAŞ

Yüksek Lisans Tezi

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

TEMMUZ 2025

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Bilgisayar Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

KURAKLIK GIDA VE SU GÜVENLİĞİ İÇİN UYDU VERİLERİNİ KULLANAN AKILLI TARIM VERİ ANALİZİ YAKLAŞIMI

Tez Yazarı
Serhat ATAŞ

Danışman
Prof. Dr. Mehmet KARAKÖSE

TEMMUZ 2025
ELAZIĞ

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Bilgisayar Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Başlığı:	Kuraklık Gıda ve Su Güvenliği İçin Uydu Verilerini Kullanan Akıllı Tarım Veri Analizi Yaklaşımı
Yazarı:	Serhat ATAŞ
İlk Teslim Tarihi:	19.06.2025
Savunma Tarihi:	14.07.2025

TEZ ONAYI

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına göre hazırlanan bu tez aşağıda imzaları bulunan jüri üyeleri tarafından değerlendirilmiş ve akademik dinleyicilere açık yapılan savunma sonucunda OYBİRLİĞİ ile kabul edilmiştir.

Danışman:	Prof. Dr. Mehmet KARAKÖSE Fırat Üniversitesi, Mühendislik Fakültesi	<i>İmza</i> Onayladım
Başkan:	Prof. Dr. İlhan AYDIN Fırat Üniversitesi, Mühendislik Fakültesi	Onayladım
Üye:	Doç. Dr. Fırat ARTUĞER Munzur Üniversitesi, Mühendislik Fakültesi	Onayladım

Bu tez, Enstitü Yönetim Kurulunun/...../20..... tarihli toplantısında tescillenmiştir.

İmza

Prof. Dr. Burhan ERGEN
Enstitü Müdürü

BEYAN

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım “ Kuraklık Gıda ve Su Güvenliği İçin Uydu Verilerini Kullanan Akıllı Tarım Veri Analizi Yaklaşımı” Başlıklı Yüksek Lisans Tezimin içindeki bütün bilgilerin doğru olduğunu, bilgilerin üretilmesi ve sunulmasında bilimsel etik kurallarına uygun davrandığımı, kullandığım bütün kaynakları atıf yaparak belirttiğimi, maddi ve manevi desteği olan tüm kurum/kuruluş ve kişileri belirttiğimi, burada sunduğum veri ve bilgileri unvan almak amacıyla daha önce hiçbir şekilde kullanmadığımı beyan ederim.

14.07.2025

Serhat ATAŞ



ÖNSÖZ

Yüksek lisans eğitimim boyunca değerli vaktini bana harcayarak her türlü desteğini veren, birlikte çalışmaktan onur duyduğum ve ayrıca tecrübelerinden yararlanırken göstermiş olduğu hoşgörü ve sabrından dolayı değerli danışmanım Prof. Dr. Mehmet KARAKÖSE'ye çok teşekkür ederim.

Ayrıca tez çalışmam boyunca bana destek olan, maddi ve manevi desteğini benden esirgemeyen değerli eşime çok teşekkür ederim.

Serhat ATAŞ
ELAZIĞ, 2025



İÇİNDEKİLER

	Sayfa
ÖNSÖZ.....	iv
İÇİNDEKİLER	v
ÖZET	vii
ABSTRACT	viii
ŞEKİLLER LİSTESİ	ix
TABLolar LİSTESİ	xi
SİMGELER VE KISALTMALAR	xii
1. GİRİŞ	1
1.1. Tarım Alanlarının Analizi	1
1.2. Literatürdeki Çalışmalar	2
1.3. Tezin Amacı ve Kapsamı	16
1.4. Tezin Yapısı.....	16
2. TARIM ALANLARININ ANALİZİNDE BİLİŞİM TEKNOLOJİLERİ.....	18
2.1. Uydu ve Meteorolojik Veri Toplama	19
2.2. Veri Ön İşleme ve Temizleme	22
2.3. Özellik Çıkarımı ve İndeks Hesaplama	23
2.4. Veri Analizi ve Modelleme	24
2.5. Görselleştirme ve Karar Destek Çıktıları.....	25
3. ÖNERİLEN YAKLAŞIM.....	27
3.1. Akış 1: Uydu Verilerine Dayalı Akıllı Tahmin Akışı.....	28
3.1.1. Uydu Platformu Seçimi ve Çalışma Alanının Tanımlanması.....	28
3.1.2. Veri Toplama	28
3.1.3. Veri İşleme ve Özellik Çıkarımı	28
3.1.4. Model Eğitimi ve Tahmin Süreci	28
3.2. Akış 2: Meteorolojik Verilere Dayalı Analiz Akışı.....	30
3.2.1. Veri Toplama	30
3.2.2. Meteorolojik Verilere Dayalı Tahmin	30
3.3. Teknik Altyapı.....	31
3.3.1. Paket Yapısı	31
3.3.2. Java.....	32
3.3.3. Spring Boot	33
3.3.4. Thymeleaf	35
3.3.5. Sentinel-2	35
3.3.6. OpenEO.....	35
3.4. Simülasyon Sonuçları	35
3.4.1. Kullanılan Veri Setleri	36
3.4.2. Uygulama Mimarisi.....	36
3.4.3. Simülasyon.....	37
3.4.3. Elde Edilen Sonuçlar ve Karşılaştırılması	39
4. KURAKLIK RİSKİ, GIDA VE SU GÜVENLİĞİ RİSK DEĞERLENDİRMESİ İÇİN DERİN ÖĞRENME TABANLI MODELLER.....	42

4.1. Kuraklık Riski	42
4.1.1. Kuraklık Riski Veri Seti	42
4.1.2. DroughtNet-X Modeli	43
4.1.3. DroughtNet-X Eğitim Performansı ve Doğruluk Değerlendirmesi	45
4.1.4. Kuraklık Riski Sonuçlarının Yorumlanması	47
4.2. Su Güvenliği	48
4.2.1. Su Güvenliği Veri Seti ve Özellikleri	49
4.2.2. WS-RiskNet Modeli	50
4.2.3. WS-RiskNet Eğitim Performansı ve Doğruluk Değerlendirmesi	51
4.2.4. Su Güvenliği Sonuçlarının Yorumlanması	53
4.3. Gıda Güvenliği	54
4.3.1. Gıda Güvenliği Veri Seti ve Özellikleri	54
4.3.2. FoodNet-C Modeli	55
4.3.3. FoodNet-C Eğitim Performansı ve Doğruluk Değerlendirmesi	57
4.3.4. Gıda Güvenliği Sonuçların Yorumlanması	60
4.4. Genel Değerlendirme	61
5. SONUÇLAR, TARTIŞMA VE ÖNERİLER	63
KAYNAKLAR	66
ÖZGEÇMİŞ	

ÖZET

Kuraklık Gıda ve Su Güvenliği İçin Uydu Verilerini Kullanan Akıllı Tarım Veri Analizi Yaklaşımı

Serhat ATAŞ

Yüksek Lisans Tezi

FIRAT ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Temmuz 2025, Sayfa: xii + 69

Bu tez çalışması, kuraklık, gıda güvenliği ve su güvenliği gibi küresel ölçekte kritik öneme sahip sorunlara çözüm sunmak amacıyla, uydu görüntüleri ve meteorolojik verilerin birlikte analiz edildiği bir akıllı tarım veri analizi yaklaşımı geliştirmeyi hedeflemektedir. İklim değişikliğinin tarımsal üretim üzerindeki etkilerinin giderek arttığı günümüzde, bu risklere karşı erken uyarı sistemlerinin ve karar destek yapılarının önemi artmaktadır. Bu kapsamda geliştirilen sistem, Sentinel-2 uydu verileri ile toprak nemi ve bitki sağlığına ilişkin spektral indekslerin hesaplanmasını ve RandomForestRegressor gibi makine öğrenmesi algoritmalarıyla mekânsal tahminlerin gerçekleştirilmesini sağlamaktadır.

Tezde, çift akışlı bir analiz mimarisi önerilmiştir. Birinci akış, uydu görüntülerine dayalı olarak tarımsal uygunluk ve çevresel stres koşullarının belirlenmesini sağlamaktadır. İkinci akış ise, OpenEO platformu üzerinden elde edilen meteorolojik verilerin işlenmesiyle kullanıcıya özgü tahmin ve öneriler sunmaktadır. Geliştirilen sistem, kullanıcı tarafından belirlenen koordinatlar üzerinden çalışabilen, gerçek zamanlı ve bölgeye özgü karar destek çıktıları sunan esnek bir yapıya sahiptir.

Ayrıca, çalışmada geliştirilen üç ayrı derin öğrenme modeli aracılığıyla kuraklık riski (DroughtNet-X), su güvenliği (WS-RiskNet) ve gıda güvenliği (FoodNet-C) analizleri gerçekleştirilmiştir. Bu modellerin eğitim süreçleri Python dili kullanılarak Google Colab ortamında yürütülmüş, doğruluk oranları literatürdeki yöntemlerle karşılaştırılarak değerlendirilmiştir.

Elde edilen bulgular, uydu ve meteorolojik verilerin birlikte kullanımının, tarımsal karar alma süreçlerinde etkinliğini artırdığını, çevresel değişkenliklere karşı daha dirençli sistemlerin kurulmasına katkı sağladığını ortaya koymaktadır. Bu bağlamda, çalışma hem akademik araştırmalar hem de saha uygulamaları için pratik ve uygulanabilir bir model sunmaktadır.

Anahtar Kelimeler: Yapay zekâ, Derin öğrenme, Uydu verileri, Meteorolojik veri, Akıllı tarım

ABSTRACT

Smart Agriculture Data Analysis Approach for Drought, Food and Water Security Using Satellite Data

Serhat ATAŞ

Master's Thesis

FIRAT UNIVERSITY
Graduate School of Natural and Applied Sciences
Department of Computer Engineering

July 2025, Pages: xii + 69

This thesis proposes a smart agriculture data analysis approach that integrates satellite imagery and meteorological data to address pressing global challenges such as drought, food security, and water security. In the context of escalating climate change and its growing impact on agricultural productivity, the development of early warning and decision support systems has become crucial. The proposed system employs Sentinel-2 satellite data to calculate spectral indices related to soil moisture and vegetation health, and applies machine learning algorithms such as RandomForestRegressor to generate spatial predictions.

The study introduces a dual-stream architecture. The first stream focuses on analyzing satellite data to assess agricultural suitability and environmental stress, while the second stream processes meteorological data retrieved from the OpenEO platform to provide user-specific insights and recommendations. One of the system's core features is its ability to perform real-time, location-based analyses defined by user-input coordinates, enabling adaptive and flexible decision-making.

Additionally, three deep learning models were developed to assess drought risk (DroughtNet-X), water security (WS-RiskNet), and food security (FoodNet-C). These models were trained and evaluated using Python in a Google Colab environment, and their performance was benchmarked against conventional methods in the literature.

The findings demonstrate that the combined use of satellite and meteorological data significantly enhances the effectiveness of agricultural decision-making processes and contributes to the resilience of food systems under environmental stress. This study offers a comprehensive and practical framework that is both scientifically rigorous and applicable to real-world agricultural management scenarios.

Keywords: Artificial intelligence, Deep learning, Satellite data, Meteorological data, Smart agriculture

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 1.1. Ghobadi ve ark. çalışmalarının metodolojik çerçevesi [25]	5
Şekil 1.2. RegCDI metodolojisinin akış şeması [26].....	6
Şekil 1.3. Ani kuraklık etkenleri kesişim kümesi [27]	7
Şekil 1.4. Lin ve ark. önerdikleri yöntemin mimarisi [28]	8
Şekil 1.5. MT-CYP-Net mimarisi [29].....	9
Şekil 1.6. Chen ve ark. tarafından yapılan çalışmanın teknik akış şeması [30].....	10
Şekil 1.7. Siasar ve ark. çalışmalarının kavramsal çerçevesi [32]	11
Şekil 1.8. Çakmakçı ve ark. ele aldığı alanlar [33].....	12
Şekil 1.9. Judith ve ark. önerdikleri model [34]	13
Şekil 1.10. Uydu verilerinin kullanıldığı karar ölçekleri ve aktörler [36]	14
Şekil 2.1. Tarım alanlarında bilişim teknolojilerinin kullanımı.....	18
Şekil 2.2. Tarımsal alanların analiz süreci.....	19
Şekil 2.3. (a) Akıllı tarımda uzaktan algılama pazarı (b) Uydu tipleri zaman eksenini.....	20
Şekil 2.4. Veri ön işleme ve temizleme adımları.....	22
Şekil 2.5. Hesaplanan başlıca indeksler.....	23
Şekil 2.6. Veri analizi ve modelleme adımları	25
Şekil 2.7. Görselleştirme ve karar destek çıktıları	26
Şekil 3.1. Önerilen yöntem blok diyagramı.....	27
Şekil 3.2. RandomForestRegressor blok diyagramı	29
Şekil 3.3. RandomForestRegressor analiz sonuçları	29
Şekil 3.4. Meteorolojik analiz sonuçları	30
Şekil 3.5. İntelij idea örnek proje oluşturma	33
Şekil 3.6. RESTful örnek kullanımı	34
Şekil 3.7. Önerilen yöntem uygulama mimarisi	37
Şekil 3.8. Örnek konum seçim ekranı.....	38
Şekil 3.9. Uydu verileri analiz sonucu.....	38
Şekil 3.10. Meteorolojik veri analiz sonucu	39
Şekil 3.11. RandomForestRegressor sonuçları.....	40
Şekil 4.1. DroughtNet-X model katmanları.....	44
Şekil 4.2. DroughtNet-X model mimarisi	45
Şekil 4.3. DroughtNet-X eğitim kayıp grafiği.....	46

Şekil 4.4. DroughtNet-X model karmaşıklık matrisi.....	47
Şekil 4.5. DroughtNet-X örnek çıktısı.....	48
Şekil 4.6. WS-RiskNet model diyagramı	50
Şekil 4.7. WS-RiskNet eğitim kayıp grafiği.....	51
Şekil 4.8. WS-RiskNet model karmaşıklık matrisi.....	52
Şekil 4.9. WS-RiskNet örnek çıktısı.....	54
Şekil 4.10. FoodNet-C model katmanları.....	56
Şekil 4.11. FoodNet-C model mimarisi.....	57
Şekil 4.12. FoodNet-C eğitim kayıp grafiği	58
Şekil 4.13. FoodNet-C model karmaşıklık matrisi	59
Şekil 4.14. FoodNet-C örnek çıktısı	61

TABLÖLAR LİSTESİ

	Sayfa
Tablo 1.1. Yapılan çalışmaların veri kaynağı ve kullanım alanları.....	14
Tablo 3.1. Önerilen yöntemde kullanılan veri setleri.....	36
Tablo 3.2. Önerilen yöntemin literatür ile karşılaştırması.....	41
Tablo 4.1. Kuraklık riski veri seti	43
Tablo 4.2. DroughtNet-X model metrikleri	46
Tablo 4.3. DroughtNet-X modelinin makine öğrenmesi yöntemleriyle karşılaştırması.....	47
Tablo 4.4. Su güvenliği veri seti	49
Tablo 4.5. WS-RiskNet model metrikleri	52
Tablo 4.6. WS-RiskNet modelinin makine öğrenmesi yöntemleriyle karşılaştırması	53
Tablo 4.7. Gıda güvenliği veri seti.....	55
Tablo 4.8. FoodNet-C model metrikleri.....	58
Tablo 4.9. FoodNet-C modelinin makine öğrenmesi yöntemleriyle karşılaştırması.....	60
Tablo 4.10. Kuraklık riski, gıda güvenliği ve su güvenliği veri setlerinin büyüklük ve öznitelik sayıları...	61
Tablo 4.11. Kuraklık riski, gıda güvenliği ve su güvenliği modellerinin literatür ile karşılaştırması	62

SİMGELER VE KISALTMALAR

Kısaltmalar

MODIS	: Moderate Resolution Imaging Spectroradiometer
OLI	: Operational Land Imager
SAR	: Synthetic Aperture Radar
MVC	: Model-View-Controller
DTO	: Data Transfer Object
JVM	: Java Virtual Machine
IDE	: Integrated Development Environment
JDK	: Java Development Kit
SE	: Java Standard Edition
EE	: Java Enterprise Edition
JWT	: Json Web Token
CRUD	: Create, Read, Update, Delete
HTTP	: Hyper Text Transfer Protocol
NDVI	: Normalized Difference Vegetation Index
NDMI	: Normalized Difference Moisture Index
CBS	: Coğrafi Bilgi Sistemi
IoT	: Internet of Things
CNN	: Convolutional Neural Network
MLP	: Multilayer Perceptron
ANN	: Artificial Neural Network
ReLU	: Rectified Linear Unit
DNN	: Deep Neural Network

1. GİRİŞ

Küresel iklim krizinin giderek derinleştiği, su kaynaklarının azaldığı ve güvenli gıdaya erişimin zora girdiği günümüz dünyasında, tarım sektörü stratejik bir alan haline gelmiştir. İklim değişikliğinin tarım ve gıda sistemleri üzerindeki etkisi, sadece verim düşüşüyle sınırlı kalmayıp gıda erişimini ve sürdürülebilir kalkınma hedeflerini de doğrudan tehdit etmektedir [1]. Bu noktada, yapay zekâ destekli sistemlerin ve uydu verilerinin kullanımıyla geliştirilen karar destek yapıları, tarım uygulamalarını daha bilimsel ve veri odaklı hale getirme potansiyeline sahiptir. İleri düzey derin öğrenme algoritmalarının uydu görüntüleriyle birleştirilmesi, tarımsal streslerin tespitinde hassas ve özgün çözümler sunabilmektedir [2].

Bu tez çalışmasında, uydu tabanlı görüntüler ve meteorolojik verilerin entegre edildiği bir akıllı tarım analiz sistemi geliştirilmiştir. Sistem, özellikle Sentinel-2 uydu verilerini kullanarak bitki sağlığı ve toprak nemi gibi kritik parametrelerin RandomForestRegressor modeli ile tahmin edilmesini sağlamaktadır. Bunun yanı sıra OpenEO platformu üzerinden elde edilen meteorolojik veriler doğrultusunda kullanıcıya basit bir algoritma ile yorumlama ve yönlendirme yapılmaktadır. Sistemin en dikkat çeken özelliği, sabit bir analiz bölgesiyle sınırlı kalmadan kullanıcı tarafından belirlenen koordinatlar üzerinden çalışabilen esnek bir yapı sunmasıdır. Bu çalışmalara ek olarak geliştirilen 3 farklı model ve elde edilen veri setleriyle kuraklık riski, gıda güvenliği ve su güvenliği analizleri yapılmıştır.

Tezde geliştirilen sistem, klasik yöntemlerin aksine, gerçek zamanlı veri toplama, analiz ve özelleştirilmiş çıktı üretme yeteneğiyle tarımsal karar alma süreçlerine çağdaş bir alternatif sunmaktadır. Tarımsal faaliyetlerle uğraşan bireylerin bulunduğu bölgelere özgü veriler üzerinden analiz yapabilmesi, hem çevresel farklılıkları dikkate alan hem de sahada daha anlamlı sonuçlar üreten modellerin ortaya çıkmasını sağlamaktadır.

1.1. Tarım Alanlarının Analizi

Tarım alanları, doğal kaynakların sürdürülebilir kullanımı ve gıda güvenliğinin sağlanması açısından stratejik bir öneme sahiptir. Tarımsal üretimdeki verimliliğin artırılması, yalnızca ürün yetiştirme süreçlerine değil, aynı zamanda çevresel koşulların detaylı analizine de bağlıdır. Arazi özellikleri, toprak kompozisyonu, nem durumu ve hava koşulları gibi parametreler, ürün gelişimini doğrudan etkileyen bileşenlerdir. Ancak, bu verilerin geniş alanlarda sürekli ve doğru şekilde takibi geleneksel gözlem yöntemleriyle oldukça sınırlıdır.

Bu nedenle uzaktan algılama teknolojileri, özellikle Sentinel-2 gibi yüksek zamansal ve mekânsal çözünürlüğe sahip çok bantlı uydu sistemleri, modern tarımsal izleme çalışmalarında yaygın olarak kullanılmaktadır. Derin öğrenme destekli uydu analizleri, ekim stratejilerinden

sulama yönetimine kadar birçok süreçte daha hassas ve sürdürülebilir kararlar alınmasına olanak sağlamaktadır [3]. Sentinel-2'nin sağladığı kırmızı yakın kızılötesi (NIR) ve kısa dalga kızılötesi (SWIR) bantları sayesinde Normalized Difference Vegetation Index (NDVI) ve Normalized Difference Moisture Index (NDMI) gibi bitki sağlığı ve toprak nemi üzerine odaklanan spektral indeksler hesaplanabilmektedir. Bu indeksler, bitki örtüsünün biyofiziksel durumunu yansıtarak kuraklık, hastalık veya su stresine dair erken uyarılar sağlamaktadır. Uydu verilerinin çiftçi düzeyinde karar destek aracı olarak kullanılabilirliği, doğru teknolojiyle buluşturulduğunda küçük tarım işletmelerinde bile önemli faydalar yaratmaktadır [4]. Son yıllarda tarımda uydu görüntüsü kullanımına dair bilimsel ilgi hızla artarken, bu alanda hem akademik hem de dijital medya düzeyinde canlı bir etkileşim ağı oluşmuştur [5].

Çalışmanın birinci adımında, 500 Sentinel-2 görüntüsünden elde edilen NDVI ve NDMI verileri, RandomForestRegressor algoritması ile işlenmiştir. Model, her bir pikselin tarımsal uygunluk düzeyini tahmin etmek amacıyla eğitilmiş; çok değişkenli regresyon yapısında, görüntü özellikleri (spektral bantlar, indeks değerleri vb.) giriş olarak kullanılmıştır. Zamansal ve spektral bilgileri birleştiren yapay zekâ modelleri, mevsimsel ürün desenlerini yüksek doğrulukla haritalayarak gıda güvenliği açısından kritik katkılar sunmaktadır [6]. Modelin hiperparametreleri (örneğin $n_estimators=100$, $max_depth=20$) çapraz doğrulama yöntemi ile optimize edilmiş ve genel başarı oranı %86 ile %88 arasında değişmiştir.

İkinci aşamada ise tarımsal kararları destekleyici meteorolojik veriler entegre edilmiştir. OpenEO platformu aracılığıyla elde edilen günlük sıcaklık, bağıl nem, yağış miktarı ve rüzgâr hızı verileri, zaman serisi formatında analiz edilmiştir. Bu analizde, her bir parametre için hareketli ortalama ve sapma bazlı eşikleme yöntemleri kullanılarak anomali tespiti yapılmıştır. Örneğin, toprak neminin kritik eşiğin altına düşmesi durumunda sulama önerisi veya sıcaklıkta ani yükseliş gözlemlendiğinde hastalık riski uyarısı verilmektedir.

Çalışmanın başka bir kısmında ise kuraklık riski, gıda güvenliği ve su güvenliği analizi için 3 farklı model ve veri seti elde edilerek harita üzerinde mekânsal analizler gerçekleştirilmiştir, bu analiz adımı her bir model için farklı veri girişleri elde edilmektedir. Bu işlem adımı, karmaşık derin öğrenme yöntemleri yerine, hafif veri madenciliği teknikleri ve kural tabanlı çıkarım motorları ile yürütülmüştür. Elde edilen çıktılar, tarımsal üreticilere günlük bazda uyarılar ve öneriler olarak sunulmuş; bu da kullanıcı dostu ve erişilebilir bir sistemin temelini oluşturmuştur.

1.2. Literatürdeki Çalışmalar

Kuraklık, tarımsal üretim üzerinde en ciddi etkileri olan doğal afetlerden biridir. Kuraklık, bitki büyümesini ve gelişimini olumsuz etkileyerek, verim kayıplarına neden olmaktadır. Kuraklık, ayrıca toprak erozyonuna ve tarımsal arazilerin kaybına da neden olabilmektedir.

Saleem ve ark. derleme çalışmasında, iklim değişikliğinin tarım ve gıda güvenliği üzerindeki doğrudan (örneğin sıcaklık artışı, değişen yağış modelleri) ve dolaylı (gıda fiyat artışı, dağıtım sorunları, besin kalitesindeki düşüş) etkileri detaylı olarak ele alınmıştır. Ayrıca, biyoçeşitlilik azalması ve ekosistem hizmetlerinin bozulmasının altı çizilmiş; iklim değişikliğiyle mücadele için güçlü ulusal ve uluslararası politikalar önerilmiştir [1]. Chinchorkar yaptığı çalışmada, uydu görüntüleri ve makine öğrenmesi tekniklerini bir araya getirerek tarım sektöründe iklim değişikliğine yönelik güvenlik açığını belirlemeyi amaçlamaktadır. Araştırmada optik ve radar sensör uydu verileri, sıcaklık, toprak nemi gibi iklim parametreleri ile birleştirilerek değerlendirilmiştir [2]. Thamizhamuthu ve ark. uydu görüntülerinden elde edilen yabancı ot yoğunluğu, ekim şemaları ve su kaynağı konumları gibi verileri CNN tabanlı derin öğrenme yöntemleriyle analiz ederek, tarımsal planlama ve yönetimde verimliliği artırmayı hedeflemiştir. Bu bütünsel yaklaşım, hassas tarım uygulamaları ve kaynak kullanımının optimizasyonu açısından güçlü bir örnek teşkil etmektedir [3]. Belal ve ark. tarafından yapılan çalışmada, kuraklık dönemlerinde tarımsal üretimdeki düşüşler incelenmiştir. Çalışmada, kuraklık riskleri değerlendirilmiştir. Uydu verileri, kuraklık riskini belirlemek, kuraklıktan etkilenen alanları izlemek ve kuraklığa karşı alınacak önlemleri planlamak için kullanılabilir [7]. Rosso ve ark. Bolivya Altiplano bölgesinde yaptıkları bu çalışma ile El Nino–Güney Salınımı (ENSO) iklim olayı ile kuraklık arasındaki ilişkiyi analiz etmiştir. Uydu görüntülerinden elde edilen bitki örtüsü verileri ve iklimsel anomaliler karşılaştırılarak kuraklığın tarımsal üretim üzerindeki etkisi mekânsal ve zamansal olarak modellenmiştir. Elde edilen bulgular, iklim değişikliği etkilerinin tarımsal sistemlerdeki izlerini ortaya koymuştur [8]. Moreno ve ark. tarafından yapılan bir başka çalışmada ise, uydu verilerinden elde edilen su stresi indeksleri kullanılarak, kuraklığın tarımsal üretim üzerindeki etkileri incelenmiştir. Çalışmada, su stresi indekslerinin, kuraklığın tarımsal üretim üzerindeki etkilerini değerlendirmede etkili bir yöntem olduğu tespit edilmiştir [9]. Kulatunga ve ark. makine öğrenmesi algoritmasına dayalı bir yöntem önererek tarımda gübrelemeyi daha etkili bir şekilde kullanmayı hedeflemiştir [10]. Zhu ve ark. insansız hava aracı verilerini kullanarak çeşitli yöntemler üzerinde çalışma sağlamış ve karşılaştırma yapmışlardır [11]. Ghazal ve ark. ekim, sulama ve hasat gibi hassas tarım aşamalarını ele alarak mevcut yaklaşım ve sorunları ele almıştır [12]. Mahmood ve ark. akıllı tarım alanında kullanılan makine öğrenmesi tekniklerini derinlemesine inceleyerek açıklayıcı bir çalışma gerçekleştirmiştir [13]. Sowmya ve ark. akıllı tarım alanında platform tasarlayarak hastalık teşhisi, pazar analizi ve sulama önerileri yapmayı sağlamıştır [14]. Botero Valencia ve ark. sürdürülebilir tarımda IoT, drone ve makine öğrenmesi yöntemlerinin ürün yönetimi, hastalık denetimi ve kaynak optimizasyonu gibi alanlardaki kullanımını sistematik olarak değerlendirmiştir [15]. Qin ve ark. kıvrıkcık marulda hastalık teşhisi, büyüme evresi sınıflandırması, verim tahmini ve yabancı ot yönetimi gibi uygulamaları incelemiştir [16]. Miller ve ark. IoT altyapısının tarımsal destek

mekanizmalarında önemli bir noktada olduğunu kanıtlamıştır [17]. Yao ve ark. yaptıkları çalışma ile yaprak hastalıklarını tanımak için kullanılan veri setleri, geleneksel makine öğrenmesi, derin öğrenme ve artırılmış öğrenme tekniklerini özetlemiştir [18]. Kallenberg ve ark. bitki büyüme modelleriyle makine öğrenmesi yöntemlerini birleştiren bir yaklaşım sunmuştur [19]. Afzal ve ark. tarımsal çıktıdaki ürün önerisinde iyileştirme sağlayabilmek için toprak bilgilerinin üzerinde makine öğrenmesi çalışmaları yapmışlardır [20].


Uydu verileri, tarımsal verimliliği artırmak için de kullanılabilir. Uydu verileri, bitki hastalıklarını ve zararlılarını tespit etmek, toprak kalitesini değerlendirmek ve su kaynaklarını daha verimli kullanmak için kullanılabilir. Poblete ve ark. zeytin ve badem ağaçlarını etkileyen *Xylella fastidiosa* ve *Verticillium dahliae* gibi iki mantar patojenine odaklanmaktadır. Çalışmanın ana bulguları, yüksek çözünürlüklü uydu görüntülerinin Xf ve Vd enfeksiyonlarını tespit etmek için kullanılabileceğini, ancak erken aşama hastalık tespitinin daha zor olduğunu göstermektedir [21]. Tunçay ve ark. tarafından yapılan çalışmada toprak verimliliği değerlendirmeleri için uzaktan algılama ve arazi çalışmaları entegre edilmiştir. Elde edilen verilerden oluşturulan "Toprak Verimliliği İndeksi", tarımsal planlamada kullanılabilecek bölgeler arası farklılıkları göstermiştir. Uygulama, özellikle yarı kurak alanlardaki tarım yönetim politikalarına katkı sunmuştur [22].

Uydu verileri, su yönetimini iyileştirmek için de kullanılabilir. Uydu verileri, su kaynaklarının miktarını ve kalitesini izlemek, sulama sistemlerini optimize etmek ve su kayıplarını azaltmak için kullanılabilir. Chawla ve ark. yapılan bir çalışmada, uydu verilerinden elde edilen su kaynaklarının miktarı ve kalite indekslerini kullanarak, su kaynaklarının yönetimi için bir model geliştirmiştir. Çalışmada geliştirilen modelin, su kaynaklarının yönetiminde etkili olduğu tespit edilmiştir [23]. Santos ve ark. tarafından yapılan bir başka çalışmada ise bir sulama sisteminin etkinliğini değerlendirmek için uydu verilerinden elde edilen göstergeler kullanılmıştır. NDVI, evapotranspirasyon ve yüzey sıcaklığı verileriyle yapılan analiz sonucunda, sistemin su kullanım verimliliği değerlendirilmiş ve sulama rejiminin optimize edilmesi sağlanmıştır [24]. Ghobadi ve ark. tarafından yapılan çalışmada İran'ın Lorestan bölgesinde çok zamanlı uydu verileri kullanılarak tarımsal kuraklık şiddeti analiz edilmiştir. NDVI, VHI gibi bitki temelli indekslerle yapılan bu analiz, kuraklığın hem şiddetini hem de yayılımını belirlemek adına bölgeye özgü bir değerlendirme sunmuştur. Çalışma ayrıca, yerel karar vericilere yönelik haritalandırma örnekleri de içermektedir. Şekil 1.1'de çalışmanın metodolojik çerçevesi verilmiştir [25].



Şekil 1.1. Ghobadi ve ark. çalışmalarının metodolojik çerçevesi [25]

Satapathy ve ark. RegCDI olarak adlandırılan birleşik bir kuraklık tahmin modeli ile MODIS ve GLDAS-2 verileri kullanmıştır. Bu yöntemle, kuraklık durumları iki ay önceden %80'in üzerinde bir doğrulukla tahmin edilmiştir. Bölgesel erken uyarı sistemlerinin geliştirilmesi açısından bu metodoloji dikkat çekicidir. Şekil 1.2'de RegCDI metodolojisinin akış şeması verilmiştir [26].



Şekil 1.2. RegCDI metodolojisinin akış şeması [26]

Christian ve ark. tarafından gerçekleştirilen bu kapsamlı çalışmada, ani kuraklık (flash drought) olayları üzerine yoğunlaşmış ve bu olağan dışı iklimsel durumların erken teşhisi için yeni nesil göstergeler geliştirilmiştir. Ani kuraklıklar, kısa süre içinde hızla gelişmeleri ve geleneksel kuraklık sinyalleriyle zamanında tespit edilememeleri nedeniyle tarımsal üretim, su yönetimi ve ekolojik denge üzerinde ciddi riskler oluşturmaktadır.

Araştırmada, klasik kuraklık indekslerinin (örneğin SPI, PDSI) yanı sıra zamansal çözünürlüğü daha yüksek, nem dengesi ve buharlaşma-temelli göstergeler entegre edilmiştir. Bu göstergeler sayesinde ani kuraklıkların başlangıç evreleri daha erken saptanabilmiş ve müdahale süresi önemli ölçüde kısaltılmıştır. Aynı zamanda, çalışmada çoklu veri kaynakları (uydu temelli bitki örtüsü indeksleri, toprak nemi ölçümleri, atmosferik parametreler) birleştirilerek kuraklıkların mekânsal yayılımı ve şiddeti haritalandırılmıştır.

Christian ve ekibi, geliştirdikleri zaman hassasiyeti yüksek modellerin doğruluk oranlarını geleneksel modellere kıyasla ciddi oranda artırdığını ortaya koymuştur. Bu modeller özellikle tarımsal erken uyarı sistemleri ve afet yönetiminde kullanılmak üzere önerilmektedir. Şekil 1.3'de çalışmanın temel indeks kümeleri ve etken faktörlerin kesişim alanları grafiksel olarak sunulmuştur. Bu yönüyle çalışma, ani kuraklıkların bilimsel olarak modellenmesi ve sahada yönetilmesi açısından önemli bir katkı sunmaktadır [27].




Şekil 1.3. Ani kuraklık etkenleri kesişim kümesi [27]

Lin ve ark. tarımsal üretim tahminlerinde iklim değişkenlerinin etkisini daha derinlemesine analiz edebilmek için "MMST-ViT" (Multi-Modal Spatio-Temporal Vision Transformer) adını verdikleri gelişmiş bir derin öğrenme modeli tasarlamışlardır. Bu model, mekânsal ve zamansal verileri aynı anda değerlendirebilen, çoklu veri kaynaklarını birleştirme yeteneğine sahip bir transformer mimarisi olarak öne çıkmaktadır.

Araştırma, ABD'nin geniş tarım alanlarında uygulanmış ve optik uydu görüntüleri ile meteorolojik veriler eş zamanlı olarak işlenmiştir. Uydu görüntüleri, bitki örtüsü ve toprak koşullarına dair görsel içerik sunarken; meteorolojik veriler (sıcaklık, nem, yağış gibi) çevresel bağlamın dinamiklerini yansıtmaktadır. Model, bu çoklu veri kaynaklarını entegre ederek koronal (mevsimsel veya yıllık) bazda mahsul verimi tahminleri yapmıştır. Bu yönüyle, yalnızca kısa vadeli tahminler sunmakla kalmayıp, uzun vadeli iklim senaryoları doğrultusunda üretim projeksiyonları oluşturmuştur.

MMST-ViT modeli, özellikle transformer temelli mimarinin sunduğu dikkat mekanizmaları sayesinde, hangi veri türünün ne zaman daha etkili olduğunu öğrenebilmekte ve karmaşık etkileşimleri modelleyebilmektedir. Bu sayede verim tahmini doğruluğu önemli ölçüde artırılmıştır. Şekil 1.4'de önerilen modelin mimarisi detaylı olarak verilmiştir. Bu mimari, sadece

tarım için değil, çevresel modelleme ve afet yönetimi gibi diğer alanlarda da kullanılabilecek güçlü bir örnektir [28].




Şekil 1.4. Lin ve ark. önerdikleri yöntemin mimarisi [28]

Liu ve ark. Çin'in Heilongjiang bölgesinde gerçekleştirdikleri bu çalışmada, tarımsal üretimde veri kıtlığı bulunan alanlarda yüksek doğrulukta mahsul verim tahmini yapabilen özgün bir yapay zekâ modeli geliştirmiştir. "MT-CYP-Net" (Multi-Task Crop Yield Prediction Network) adını verdikleri bu mimari, hem noktasal (alan temelli) hem de piksel seviyesinde (detay bazlı) tahminlerde bulunabilme kapasitesine sahiptir. Bu sayede, sınırlı uydu görüntüsü ve yer verisi bulunan bölgelerde bile tutarlı ve güvenilir tahminler yapılabilmektedir.


Model, çoklu görevli bir yapıya sahip olup, aynı anda farklı ölçeklerde veri öğrenimi gerçekleştirebilmektedir. Özellikle, Sentinel verileri gibi orta çözünürlüklü uydu kaynakları ile eğitildiğinde dahi, tarla bazında verim tespitini başarıyla yapabilmektedir. Ayrıca, modelin mimarisi sayesinde yalnızca mevcut verileri işlemekle kalmayıp, geçmiş sezonlardan öğrenilen örüntüler üzerinden geleceğe yönelik çıkarımlarda da bulunulmuştur.

Çalışma, sınırlı etiketli veriye rağmen tarım alanlarında derin öğrenmenin etkinliğini gösteren başarılı bir örnektir. Şekil 1.5'de, MT-CYP-Net mimarisinin yapısı ve veri akışı şematik olarak sunulmuştur. Bu mimari, düşük örneklem sayısına sahip alanlar için uyarlanabilir bir yapay zekâ çözümü sunarak, sürdürülebilir tarımsal karar destek sistemlerine katkı sağlamaktadır [29].



Şekil 1.5. MT-CYP-Net mimarisi [29]


Chen ve ark. tarafından, Çin'in doğu bölgelerinde kuraklık izlemek üzere Interpretable Machine Learning Drought Index (IMLDI) adlı yeni bir indeks tanıtılmıştır. Güneş kaynaklı klorofil floresansı (SIF), toprak nemi, yeryüzü sıcaklığı ve su dengesi gibi çoklu uzaktan algı verileri LightGBM modeli ve SHAP analiziyle entegre edilerek yorumlanabilir bir model oluşturulmuştur. İndeks, PCA, çoklu regresyon gibi karşılaştırmalı yöntemlere göre daha yüksek uyum göstermekte (SPEI ile taşıdığı korelasyon), özellikle 2009/10 ve 2019 yıllarındaki önemli kuraklık dönemlerini başarılı şekilde yansıtmaktadır. Teknik akış şemaları aşağıda Şekil 1.6'da verilmiştir [30].



Şekil 1.6. Chen ve ark. tarafından yapılan çalışmanın teknik akış şeması [30]


Zha ve ark. kurak bölgelerde toprak nemi tahmini için uydu verileri bazlı ML yöntemi uygulamış; Sentinel/SMAP verileriyle birlikte sınır bölgelere yönelik yüksek başarı elde etmişlerdir. Belirtmiş oldukları Richards denkleminde dayalı olarak Kuzey Çin Ovası'ndaki farklı mekânsal katmanlardaki toprak neminin tahmin edilmesine yönelik akış sunmuşlardır [31].

Siasar ve ark. tarafından yapılan çalışmada, 2000–2019 dönemi için MODIS, TRMM ve GridSat-B1 verileri kullanılarak VCI, TCI, VHI, CI, PCI indeksiyle bölgesel kuraklık analizi yapılmıştır. Google Earth Engine üzerinden yürütülen işlem boyunca mekânsal haritalar ve zaman serileri ortaya çıkarılmıştır. Ayrıca, toprak nemi, sıcaklık değişimleri ve bitki sağlığı detaylı şekilde incelenmiştir. Kavramsal çerçeveleri aşağıda Şekil 1.7'de verilmiştir [32].



Şekil 1.7. Siasar ve ark. çalışmalarının kavramsal çerçevesi [32]


Çakmakçı ve ark. tarafından yapılan çalışmada, tarım sektöründe dijitalleşmenin önemini vurgulayarak Tarım 4.0 uygulamalarını ve bunların tarımsal üretime etkilerini incelemektedir. Uzaktan algılama, yapay zekâ, nesnelerin interneti, büyük veri ve robotik sistemler gibi ileri teknolojilerin tarımda nasıl kullanıldığını ele alır. Tarımsal verimliliği artırmak, kaynak kullanımını optimize etmek ve sürdürülebilir tarımı desteklemek amacıyla bu teknolojilerin bütüncül şekilde bütünleşmiş olması gerekliliği savunulmaktadır. Aynı zamanda, bu teknolojilerin benimsenmesinde karşılaşılan zorluklara (maliyet, eğitim, teknik altyapı eksikliği) da değinilir. Çalışma, akıllı tarım teknolojilerinin yaygınlaştırılmasıyla hem gıda güvenliğinin sağlanabileceğini hem de kırsal kalkınmaya katkı sunulabileceğini ortaya koymaktadır. Çalışmanın değindiği noktalar aşağıda Şekil 1.8’de verilmiştir [33].



Şekil 1.8. Çakmakçı ve ark. ele aldığı alanlar [33]

Judith ve ark. tarafından gerçekleştirilen bu araştırma, uzaktan algılama verilerine dayalı olarak stresli (hastalık veya su stresi altındaki) bitkilerin sınıflandırılmasına odaklanmıştır. Çalışmada özellikle bitki sağlığı izleme sistemlerinin geliştirilmesine katkı sunacak biçimde, NDVI (Normalized Difference Vegetation Index) değerleri kullanılarak bitki örtüsünün durumu değerlendirilmiştir. Bitki sağlığı verileri, tam bağlantılı sinir ağı (Fully Connected Neural Network - FCNN) mimarisi ile işlenmiş ve bu model aracılığıyla stresli ve sağlıklı bitkiler yüksek doğrulukla ayrıştırılmıştır.


Araştırmada önerilen yöntem, erken evrede bitki hastalıklarının uzaktan tespitini mümkün kılmakta ve üretim kayıplarını önlemeye yardımcı olmaktadır. Bu yönüyle çalışma, gerçek zamanlı karar destek sistemlerine uyum açısından öncü niteliktedir. Ayrıca, düşük çözünürlüklü uydu verilerinde dahi etkin sonuçlar verebilmesi, modelin tarım uygulamalarında yaygınlaştırılabilirliğini artırmaktadır. Şekil 1.9’da önerilen sinir ağı modelinin yapısı ve iş akışı görsel olarak sunulmuştur [34].



Şekil 1.9. Judith ve ark. önerdikleri model [34]

Aldhahri ve ark. tarafından yapılan çalışma, kentsel tarım uygulamalarında yapay zekâ temelli karar destek sistemlerinin etkinliğini artırmayı amaçlamaktadır. Bu kapsamda, ResNet ve Xception gibi güçlü derin öğrenme yapılarını birleştiren ve filtreleme özelliğine sahip özel bir model geliştirilmiştir. Model, eksik verilerin tamamlanması, verilerin dengelenmesi, önemli özelliklerin seçilmesi ve çevresel koşulların dikkate alınması gibi birçok gelişmiş ön işleme tekniği ile desteklenmiştir. Araştırmada geliştirilen sistem, %98,5 doğruluk değeri elde ederek, diğer yaygın kullanılan derin öğrenme modellerine kıyasla daha başarılı sonuçlar vermiştir. Ayrıca sistemin hızlı çalışması ve farklı çevresel koşullarda da yüksek başarı sağlaması, kentsel tarım alanında gerçek zamanlı uygulamalara uygunluğunu göstermektedir [35].

Jewiss ve ark. geliştirmekte olan ülkelerde uydu tabanlı verilerin mobil destekli karar sistemlerine nasıl entegre edilebileceğini, ayrıca bu verilerin çiftçi düzeyinden küresel politika yapıcılara kadar birçok aktör tarafından nasıl kullanılabileceğini sistematik bir tablo ve örnek ölçeklerle ortaya koymuştur. Şekil 1.10'da yer alan üçgen diyagram, tarımsal karar destek süreçlerinde uydu verilerinin farklı ölçeklerdeki kullanıcılar ve karar alanlarıyla nasıl eşleştiğini sistematik biçimde göstermektedir. Diyagramın üst kısmından alt kısmına doğru ilerledikçe, bireysel aktörlerden kurumsal ve küresel aktörlere geçiş söz konusudur. Her katman hem veri kullanan aktör tipini hem de bu aktörlerin aldığı kararların kapsamını yansıtır [36].



Şekil 1.10. Uydu verilerinin kullanıldığı karar ölçekleri ve aktörler [36]

Aşağıda Tablo 1.1’de kuraklık ve tarımsal üretim ilişkisini ele alan güncel bilimsel çalışmalardan derlenen bilgiler yer almaktadır. Literatürde öne çıkan bu çalışmalar, farklı uzaktan algılama verileri (örneğin Sentinel, MODIS, SMAP), iklim ve toprak verileri ile tarım alanlarında yapılan analizlerin zenginliğini ortaya koymaktadır. Kuraklık şiddetinin mekânsal ve zamansal düzeyde modellenmesi, toprak neminin tahmini, mahsul verimi tahmini ve bitki hastalıklarının uzaktan algı ile teşhisi gibi konular bu çalışmalarda ortak temalardır. Her bir çalışma, farklı bir metodolojik yaklaşım ve veri türü kullanarak, kuraklıkla mücadele ve tarımsal verimliliğin artırılması konularına katkı sunmaktadır. Uydu verilerinin yorumlanabilir yapay zekâ modelleriyle birleştirilmesiyle hem karar destek sistemleri geliştirilebilmekte hem de tarımsal riskler önceden tahmin edilerek sürdürülebilir tarım politikalarına zemin hazırlanmaktadır.

Tablo 1.1. Yapılan çalışmaların veri kaynağı ve kullanım alanları

Çalışmanın Yılı	Referans	Veri Kaynağı	Kullanım Alanları
2023	Belal ve ark. [7]	Uydu verileri	Kuraklık dönemlerinde tarımsal üretimdeki düşüşü inceleme
2024	Rosso ve ark. [8]	Uydu görüntüleri, iklim verileri	Kuraklık şiddeti sınıflandırması ve zamansal/mekânsal değişim

2023	Moreno ve ark. [9]	Uydu verileri, su stresi indeksleri	Su stresi ile tarımsal üretim ilişkisini analiz etme
2024	Poblete ve ark. [21]	Yüksek çözünürlüklü uydu verileri	Bitki hastalıklarının uzaktan algı ile tespiti
2023	Tunçay ve ark. [22]	Uydu verileri, toprak verimliliği indeksleri	Toprak verimliliği bölgeleri oluşturma
2023	Chawla ve ark. [23]	Uydu verileri, su kalitesi ve miktarı indeksleri	Su kaynaklarının yönetimi için model geliştirme
2024	Santos ve ark. [24]	Uydu verileri, sulama verimliliği indeksleri	Sulama sistemlerinin verimliliğini artırma
2025	Ghobadi ve ark. [25]	Uzaktan algılama verileri	Tarımsal kuraklık şiddetini değerlendirme
2025	Satapathy ve ark. [26]	MODIS yüzey yansımaları, GLDAS-2	Kuraklığı iki ay önceden tahmin etme (RegCDI)
2024	Christian ve ark. [27]	Kuraklık göstergeleri	Ani kuraklıkların erken teşhisi
2024	Lin ve ark. [28]	Optik uydu verileri, meteorolojik veriler	Koronal bazlı mahsul tahmini (Multi-modal model)
2024	Liu ve ark. [29]	Uydu verileri (MT-CYP-Net modeli)	Mahsul verim tahmini (noktasal ve piksel seviyede)
2025	Chen ve ark. [30]	SIF, toprak nemi, LST (LightGBM, SHAP)	Yorumlanabilir kuraklık indeksi geliştirme (IMLDI)
2024	Zha ve ark. [31]	Sentinel/SMAP verileri	Toprak nemi tahmini (Richards denklemiyle)
2024	Siasar ve ark. [32]	MODIS, TRMM, GridSat-B1	Kuraklık indeksleriyle mekânsal analiz

2023	Çakmakçı ve ark. [33]	Çoklu veri: AI, IoT, robotik, uzaktan algı	Tarım 4.0 uygulamalarının değerlendirilmesi
2024	Judith ve ark. [34]	NDVI, FCNN ile bitki sağlığı verisi	Stresli bitki sınıflandırması (erken hastalık tespiti)
2025	Aldhahri ve ark. [35]	Toprak, iklim ve NDVI verileri	Kentsel tarımda ürün tahmini, kaynak optimizasyonu ve karar destek sistemleri

1.3. Tezin Amacı ve Kapsamı

Bu tezin temel amacı, tarım alanlarının uzaktan algılama ve meteorolojik veriler kullanılarak analiz edilmesi ve bu analizlerin sahaya yönelik anlamlı bilgiler üretecek şekilde bir sistem haline getirilmesi ve kuraklık riski, gıda güvenliği ve su güvenliği analizleri yapmaktır. Çalışmada geliştirilen sistem iki ana akış üzerinden çalışmaktadır. Akış 1, uydu görüntülerini kullanarak RandomForestRegressor ile model çıktıları üretmekte; Akış 2 ise meteorolojik verileri yorumlayarak kullanıcıya öngörüler sunmaktadır. Başka bir adımda ise kuraklık riski, gıda güvenliği ve su güvenliği analizi için 3 farklı model ve veri seti elde edilerek harita üzerinde mekânsal analizler gerçekleştirilmiştir.

Sistem, web tabanlı bir arayüz ile gerçek zamanlı ve lokasyon bazlı analiz sunabilmektedir. Buna ek olarak farklı modeller ile kuraklık riski, gıda güvenliği ve su güvenliği analizleri yapılabilmektedir. Bu yönüyle geleneksel sabit alanlı analiz yaklaşımlarının ötesine geçmekte; özelleştirilmiş, ihtiyaca uygun çözümler sunabilmektedir. Tezin kapsamında hem sistemlerin yazılım geliştirme süreci hem de çıktıların literatürle karşılaştırılması yer almaktadır. Sistemler, performans testlerinden başarıyla geçmiş; sınırlı sayıda veriyle dahi yüksek doğruluk sunmuştur.

1.4. Tezin Yapısı

Bu tez çalışması, kapsamlı bir araştırma planına göre beş ana bölüm altında yapılandırılmıştır. Her bir bölüm, çalışmanın bütünsel amacına hizmet edecek biçimde birbirini tamamlayan içerikler sunmaktadır:

- **Giriş:** Bu bölümde araştırmanın dayandığı temel problemler, konu seçiminin gerekçesi, çalışmanın amacı ve kapsamı ile birlikte kullanılan genel yöntemsel yaklaşım açıklanmıştır. Ayrıca kuraklık, gıda ve su güvenliği bağlamında neden bu konunun ele alındığına dair bilimsel ve pratik gerekçeler sunulmuştur.
- **Tarım Alanlarının Analizinde Bilişim Teknolojileri:** Bu kısımda, akıllı tarım sistemlerinin temel bileşenleri olan uzaktan algılama teknolojileri, meteorolojik veri kaynakları, sensör uygulamaları ve yapay zekâ tabanlı analiz teknikleri detaylı şekilde


incelenmiştir. Uydu verilerinin tarımsal karar destek sistemlerindeki rolü ve veri işleme yöntemleri teorik çerçevede ele alınmıştır.

- **Önerilen Yaklaşım:** Bu bölüm, tez kapsamında geliştirilen iki akışlı akıllı tarım analiz sisteminin yapısını açıklamaktadır. Uydu verilerine dayalı öznitelik çıkarımı ve meteorolojik verilere dayalı karar destek mekanizması, adım adım teknik diyagramlarla sunulmuştur. Her iki sistemin işleyiş mantığı, kullanılan algoritmalar, yazılım mimarisi ve entegrasyon süreçleri detaylandırılmıştır. Bu bölümde simülasyon sonuçları başlığı altında geliştirilen sistemin işlevselliği sahadan elde edilen verilerle test edilmiştir. Hem uydu görüntüleri hem de meteorolojik ölçümler üzerinden yapılan analizler sunulmuş, tahmin başarımları grafiklerle karşılaştırmalı olarak değerlendirilmiştir. Modelin doğruluk oranları, kullanıcı arayüzü çıktıları ve sistemin genel performansı bu kısımda raporlanmıştır.
- **Kuraklık Riski, Gıda ve Su Güvenliği:** Tarımsal sürdürülebilirliği tehdit eden çevresel riskler, üç ana başlık altında ele alınmıştır. Kuraklık riski (DroughtNet-X), su güvenliği (WS-RiskNet) ve gıda güvenliği (FoodNet-C) için geliştirilen derin öğrenme modelleri, veri kaynakları, sınıflandırma yöntemleri ve mekânsal analiz sonuçlarıyla birlikte ayrıntılı olarak sunulmuştur. Tüm analizler Google Colaboratory üzerinde Python yazılım dili kullanılarak gerçekleştirilmiştir.
- **Sonuçlar, Tartışma ve Öneriler:** Araştırma sürecinde elde edilen bulgular bütüncül olarak değerlendirilmiş, hem teorik katkılar hem de uygulama alanlarındaki potansiyel etkiler tartışılmıştır. Bunun yanı sıra sistemin sınırlılıkları belirtilmiş ve gelecek çalışmalarda yapılabilecek geliştirmelere dair öneriler sunulmuştur.

Bu yapı, çalışmanın hem akademik literatürde bir boşluğu doldurmasını hem de uygulamada sahaya dönük çözümler üretmesini sağlamayı hedeflemektedir. Her bir bölüm, çalışmanın özgünlüğünü ve uygulanabilirliğini destekleyecek biçimde titizlikle kurgulanmıştır.

2. TARIM ALANLARININ ANALİZİNDE BİLİŞİM TEKNOLOJİLERİ

Tarım sektörü, nüfus artışı, iklim değişikliği ve kaynakların giderek azalması gibi küresel sorunlarla karşı karşıya kalmıştır. Yakın geçmişte, entegre su kaynakları yönetimi, tüm dünyada hükümetler ve paydaşlar arasında ortaya çıkan suyla ilgili çok çeşitli çatışmaların çözümü için tercih edilen yöntem olarak ortaya çıkmıştır. Çeşitli düzenleme ve girişimler uygulamaya konulmasına rağmen, bunların fiili olarak uygulanması konusunda hâlâ şüpheler var [37]. Yaklaşık çeyrek asır içerisinde dünya nüfusunun yoğun artışıyla gıda talebinin aşırı artması beklenmektedir [38]. Bu bağlamda, tarımsal üretimde verimliliği artırmak, çevresel sürdürülebilirliği sağlamak ve kaynak kullanımını optimize etmek amacıyla bilişim teknolojilerinden yoğun bir şekilde faydalanılmaktadır. Bu teknolojiler, tarım alanlarının analizi, izlenmesi, değerlendirilmesi ve yönetimi açısından önemli katkılar sunmaktadır. Genel olarak tarım alanlarında bilişim teknolojilerinin kullanımı Şekil 2.1’de verilmiştir.



Şekil 2.1. Tarım alanlarında bilişim teknolojilerinin kullanımı

Bu bölümde, özellikle uydu verileri, meteorolojik analizler ve sensör teknolojilerinin tarımsal uygulamalardaki rolü detaylı olarak ele alınmaktadır. Akıllı tarım uygulamalarında tarımsal alanların analizine yönelik kullanılan bilişim teknolojileri sistematik bir şekilde ele alınmıştır. Aşamalar, Şekil 2.2’de sunulan iş akışına göre yapılandırılmış ve her adımda uygulanan teknikler detaylandırılmıştır.



Şekil 2.2. Tarımsal alanların analiz süreci

2.1. Uydu ve Meteorolojik Veri Toplama

Akıllı tarım sistemlerinin temel yapı taşı, geniş alanlardan hızlı ve tekrarlanabilir veri toplanmasını mümkün kılan uzaktan algılama sistemleridir. Özellikle Sentinel-2, MODIS ve Landsat gibi platformlar; multispektral bantlar aracılığıyla bitki sağlığı, toprak nemi, yüzey sıcaklığı gibi kritik parametrelerin zaman serisi hâlinde izlenmesine olanak tanımaktadır. Parra Lopez ve ark. yaptıkları çalışma ile uzaktan algılama sistemlerinin yıllar içerisinde artma olduğunu göstermiştir [39]. Son üç yıl içerisinde bu sistemlerin akıllı tarım pazarındaki etkisi hızla artmış ve

Ayrıca OpenEO gibi açık veri sağlayıcıları sayesinde sıcaklık, yağış, rüzgâr ve nem gibi meteorolojik bilgiler konum bazlı olarak elde edilebilmektedir. Bu veriler sayesinde kullanıcıya özgü alanlar seçilerek konum bazlı analiz altyapısı oluşturulmuştur. Uydu ve meteorolojik veri kaynaklarının entegre edilmesi, sadece arazi gözlemine değil; aynı zamanda iklim temelli tarımsal risklerin de izlenmesine olanak sağlar.

Kullanılan başlıca uydu sistemleri şunlardır:

- **MODIS (Moderate Resolution Imaging Spectroradiometer)**

Sensör: MODIS, düşük, orta ve yüksek çözünürlükteki spektral bantlarda veri toplar.

Kullanım Alanları: Bitki örtüsü izleme, toprak nem içeriği analizi, iklim değişikliği gözlemleri.

- **Landsat Serisi**

Sensör: Özellikle Landsat 8 OLI (Operational Land Imager) sensörü, yüksek çözünürlükteki çok spektralli veri sağlar.

Kullanım Alanları: Tarım alanlarının izlenmesi, su kaynaklarının analizi, kentsel değişim gözlemleri.

- **Sentinel Serisi**

Sentinel-2, yüksek çözünürlükte çok spektralli veri sağlar.

Kullanım Alanları: Bitki sağlığı, tarım alanlarının izlenmesi, su kalitesi analizi.

- **TerraSAR-X**

Sensör: SAR (Synthetic Aperture Radar) teknolojisi kullanır.

Kullanım Alanları: Toprak nem içeriği, arazi deformasyon analizi.

- **Aqua ve Terra Uyduları**

Sensör: MODIS gibi çeşitli spektral bantlarda veri sağlar.

Kullanım Alanları: İklim değişikliği izleme, okyanus sıcaklığı analizi.

Kullanılan başlıca meteorolojik veri sistemleri şunlardır:

- **OpenEO Platformu**

Veri tipi: ERA5 üzerinden sıcaklık, nem, yağış, rüzgâr hızı

Özellikleri: REST API üzerinden konum-zaman seçimiyle veri erişimi

Kullanım amacı: Gerçek zamanlı hava durumu entegrasyonu ve analiz

- **Google Earth Engine (GEE)**

Veri tipi: NOAA, CHIRPS, ERA-Interim gibi kaynaklardan meteorolojik veriler

Özellikleri: Python ve JavaScript API desteği, zaman serisi analizi

Kullanım amacı: Gelişmiş uzamsal sorgularla tarihsel iklim verileri

- **Copernicus Climate Data Store (CDS)**

Veri tipi: ERA5 reanaliz verileri, toprak nemi, güneşlenme, buharlaşma

Özellikleri: Python API ile script tabanlı çekim

Kullanım amacı: Model girdisi ve agroklimatik değerlendirmeler

- **TR-AgroMeteoroloji İstasyon Ağı (Türkiye'ye özgü)**

Veri tipi: Anlık ve geriye dönük sıcaklık, yağış, nem

Kullanım amacı: Yerli ölçümle uydu verilerinin karşılaştırılması

Bu sistemler, analiz yapılacak coğrafi konuma göre seçilen zaman aralığında veri sağlayabilmekte; otomatik tahmin sistemlerinin ve kural tabanlı uyarıların temelini oluşturmaktadır.

2.2. Veri Ön İşleme ve Temizleme

Uydu verileri, tarım alanlarının, bitki örtüsünün ve su kaynaklarının uzaktan izlenmesinde önemli bir araçtır. Bu veriler, geniş alanlarda gerçek zamanlı gözlemler yapma kapasitesine sahip olmaları nedeniyle tarım yönetimi ve su kaynaklarının sürdürülebilir kullanımında kritik bir rol oynamaktadır [40]. Fakat Ham uydu ve meteorolojik veriler doğrudan analizde kullanılamaz; zira çeşitli hatalar ve sapmalar barındırabilir. Bu nedenle ön işleme süreci, analitik doğruluğun ve model güvenilirliğinin sağlanması açısından kritik bir aşamadır. Bu süreçte kullanılan başlıca teknikler aşağıda Şekil 2.4'de verilmiş ve açıklanmıştır.



Şekil 2.4. Veri ön işleme ve temizleme adımları


Bu süreçte kullanılan başlıca teknikler şunlardır:

- **Bulut Filtresi:** Sentinel görüntülerinde atmosferik koşullardan kaynaklanan bulut örtüsü, NDVI ve NDMI hesaplamalarında hatalara neden olur. Bu nedenle bulut maskesi uygulanarak bu bölgeler dışlanır.
- **Spektral Düzeltme:** Işık yansıma verilerinin topoğrafik eğimden kaynaklı sapmaları giderilir.
- **Zaman Eşleştirme:** Meteorolojik verilerle uydu görüntülerinin zaman serileri eşleştirilerek senkronizasyon sağlanır.
- **Koordinat Standartlaştırması:** Veriler, WGS84 sistemine göre yeniden projeksiyona tabi tutulur.

Bu işlemler sonucunda analiz için kullanılacak temiz, tutarlı ve zamansal uyumlu veri kümeleri oluşturulmuş olur.

2.3. Özellik Çıkarımı ve İndeks Hesaplama

Uydu verileri, tarım alanlarında bitki sağlığı, su durumu ve toprak özellikleri gibi faktörlerin analizinde kullanılarak tarımsal üretimi optimize etme potansiyeline sahiptir. Tarım alanlarında toprak sağlığının bozulması, gıda ve kaynak güvenliğine tehdit oluşturan küresel bir sorundur [41]. Bu bağlamda, Veri madenciliği uygulamaları açısından, ham verilerin öznetelik düzeyinde anlamlandırılması büyük önem taşır. Bu nedenle işlenen uydu görüntüleri üzerinden çok sayıda vejetasyon ve nem temelli indeks hesaplanır. Bu indeksler, bitki örtüsünün stres durumu, su ihtiyacı ve verim potansiyelini gösteren sayısal çıktılardır. Hesaplanan başlıca indeksler aşağıda Şekil 2.5’de verilmiş ve açıklanmıştır.



Şekil 2.5. Hesaplanan başlıca indeksler


Hesaplanan başlıca indeksler:

- **NDVI:** Bitki yeşil dokusu ölçümü (NIR - RED)
- **NDMI:** Nem durumu (NIR - SWIR)
- **VCI:** Bitki sağlığına göre normalize NDVI
- **TCI:** Sıcaklık kaynaklı stres analizi
- **VHI:** NDVI + TCI'nin ağırlıklı bileşkesi
- **EVI:** NDVI'ya alternatif, atmosferik etkileri minimize eden indeks

2.4. Veri Analizi ve Modelleme

Uydu kaynaklı yüksek çözünürlüklü görüntüler, tarımsal alanların geniş ölçekte izlenmesine ve zamansal mekânsal değişimlerin detaylı biçimde analiz edilmesine olanak tanımaktadır [42]. Bu tür veriler, özellikle toprak durumu ve bitki örtüsü sağlığı gibi tarım için kritik parametrelerin değerlendirilmesinde önemli bir rol üstlenmektedir. Öte yandan kuraklık, iklim değişikliği ile birlikte etkisi artan ve tarımsal verimliliği doğrudan tehdit eden doğal bir felaket türü olarak ön plana çıkmaktadır [43].

Bu doğrultuda, elde edilen uydu verileri üzerinden çıkarılan öznitelikler; istatistiksel öğrenme teknikleriyle işlenerek belirli çevresel koşulların tahmin edilmesine olanak sağlayan modellerin oluşturulmasında kullanılmalıdır. Bu adım aşağıda Şekil 2.6'da verilmiştir.



Şekil 2.6. Veri analizi ve modelleme adımları

Elde edilen tahmin çıktıları, incelenen bölgedeki bitki örtüsünün sağlığı, toprak nem düzeyi ve genel çevresel risk profili hakkında önemli göstergeler sunmalıdır. Bu göstergeler, sürdürülebilir tarım uygulamaları çerçevesinde alınacak önlemlerin ve müdahale planlarının oluşturulmasında karar destek aracı olarak işlev görmektedir.

2.5. Görselleştirme ve Karar Destek Çıktıları

Elde edilen sayısal sonuçlar, üreticilere sade ve işlevsel bir arayüzle sunulmalıdır. Bu nedenle, görselleştirme adımı sistemin en kritik bileşenlerinden biridir.

Üretilen çıktılar arasında:

- NDVI yoğunluk haritaları
- Kuraklık zonları
- Uyarı mesajları (örneğin: "Toprak nemi kritik eşiğin altında")
- Kullanıcıya özel günlük öneriler

Karar destek sistemi, hem görsel hem metinsel çıktılar sunarak çiftçilerin sulama, gübreleme, ilaçlama gibi işlemleri daha bilinçli yapmasına olanak tanımaktadır. Bu durum tarımsal üretimin çevresel etkisini azaltmakla kalmaz, aynı zamanda kaynak kullanım verimliliğini de artırır. Önerilen görselleştirme ve karar destek çıktısı aşağıda Şekil 2.7’de verilmiştir.



Şekil 2.7. Görselleştirme ve karar destek çıktıları

3. ÖNERİLEN YAKLAŞIM

Bu çalışma kapsamında, kuraklık, gıda ve su güvenliği konularına yönelik olarak akıllı tarım verilerinin analizi için uydu ve meteorolojik verilere dayalı çift aşamalı bir yaklaşım önerilmiştir. Önerilen yöntem Şekil 3.1’de blok diyagramı olarak sunulmuştur. Yaklaşımın temel amacı, yüksek çözünürlüklü uydu görüntülerinden elde edilen spektral bilgiler ile meteorolojik verilerin bir arada değerlendirilmesi yoluyla bitki sağlığı ve toprak nemi üzerine tahminlerde bulunmak ve üreticilere karar desteği sağlamaktır.



Şekil 3.1. Önerilen yöntem blok diyagramı

3.1. Akış 1: Uydu Verilerine Dayalı Akıllı Tahmin Akışı

Bu akışta, Sentinel-2 yüksek çözünürlüklü uydu platformundan elde edilen multispektral görüntüler kullanılmaktadır. Bu görüntüler, ön işleme aşamasında bulut filtresi ve atmosferik düzeltmelerden geçirilerek analiz için uygun hale getirilir.

3.1.1. Uydu Platformu Seçimi ve Çalışma Alanının Tanımlanması

Bu çalışmada, uzaktan algılama için Sentinel-2 platformu tercih edilmiştir. Sentinel-2, 10 ila 60 metre arasında değişen mekânsal çözünürlükte çok sayıda spektral bant sunmaktadır. Özellikle kırmızı, kızılötesi ve kısa dalga kızılötesi (SWIR) bantları, bitki sağlığı ve toprak nemi analizi için kullanılabilirliği yüksek veriler sağlamaktadır. Araştırma alanı, kullanıcı tarafından harita arayüzü üzerinden belirlenen koordinatlarla tanımlanır ve sistem bu alanı giriş olarak kullanır.

3.1.2. Veri Toplama

Belirlenen coğrafi bölgeye ait Sentinel-2 görüntüleri, ESA'nın Copernicus Açık Erişim Merkezi üzerinden indirilir.

3.1.3. Veri İşleme ve Özellik Çıkarımı

Verilerin işlenmesinde açık kaynak yazılımlar kullanılarak NDVI (Normalized Difference Vegetation Index) ve NDMI (Normalized Difference Moisture Index) hesaplamaları gerçekleştirilmiştir. Bu indeksler, bitki örtüsü yoğunluğu ve toprak nem düzeylerini yansıtan güvenilir parametrelerdir. Elde edilen bu değerler, her piksel bazında öznitelik matrisi haline getirilmiştir.


3.1.4. Model Eğitimi ve Tahmin Süreci

Oluşturulan öznitelik vektörleri, RandomForestRegressor algoritmasına giriş olarak verilmiştir. RandomForestRegressor, 500 görüntü örneği üzerinden kullanılmıştır. Hiperparametre optimizasyonu ile `n_estimators`, `max_depth` ve `max_features` gibi değerler belirlenmiş, RandomForestRegressor tahmin doğruluğu artırılmıştır. Sonuç olarak, sistem her yeni uydu görüntüsünde bitki sağlığı ve toprak nemi tahminleri üretmektedir.


Random Forest Regressor, makine öğrenmesinde sıklıkla tercih edilen, gözetimli öğrenmeye dayalı, topluluk temelli bir regresyon modelidir. Bu yöntem, birden fazla karar ağacının birlikte çalıştığı bir yapı üzerine kuruludur. Modelin temel prensibi, çok sayıda zayıf tahmin ediciden oluşan karar ağaçlarının sonuçlarının birleştirilmesiyle daha güçlü ve genellenebilir bir

tahmin elde edebilmesidir. Her bir ağaç, eğitim verisinin farklı bir alt kümesi üzerinde inşa edilir. Bu alt kümeler, örneklem olarak oluşturulur. Ayrıca, her ağaç için özelliklerin rastgele bir alt kümesi kullanılır, bu sayede ağaçlar arasında çeşitlilik sağlanır. Regresyon görevlerinde her ağacın yaptığı tahminlerin ortalaması alınarak nihai sonuç elde edilir. Bu yaklaşım, hem modelin aşırı öğrenme eğilimini azaltır hem de gürültülü veriler karşısında daha dayanıklı sonuçlar verir.

RandomForestRegressor blok diyagramı aşağıdaki Şekil 3.2’de, RandomForestRegressor analiz sonucu ise Şekil 3.3’de verilmiştir.



Şekil 3.2. RandomForestRegressor blok diyagramı



Şekil 3.3. RandomForestRegressor analiz sonuçları

3.2. Akış 2: Meteorolojik Verilere Dayalı Analiz Akışı

İkinci akışta ise OpenEO platformu üzerinden erişilen meteorolojik veriler kullanılmaktadır. Bu veriler, kullanıcının belirlediği konum ve zaman aralığına göre alınmakta ve dinamik analizlere tabi tutulmaktadır.

3.2.1. Veri Toplama


OpenEO API'si kullanılarak belirlenen bölge ve zaman aralığına ait meteorolojik veriler alınmaktadır.

Bu veriler aşağıdaki tarımsal üretimi doğrudan etkileyen parametreleri içermektedir:

- Günlük toplam yağış (mm)
- Ortalama hava sıcaklığı (°C)
- Bağıl nem (%)
- Rüzgâr hızı (m/s)

3.2.2. Meteorolojik Verilere Dayalı Tahmin

Alınan meteorolojik veriler, önceden tanımlanmış eşik değerlere göre arka planda çalışan bir analiz modülünde değerlendirilir. Böylece, örneğin aşırı sıcaklık veya düşük yağış öngörüsü durumlarında kullanıcıya sulama önerisi gibi otomatik karar destek çıktıları sunulmaktadır. Bu akışın örnek analiz sonuçları Şekil 3.4'de verilmiştir.



Şekil 3.4. Meteorolojik analiz sonuçları

3.3. Teknik Altyapı

Bu çalışmalar IntelliJ IDEA üzerinde geliştirilmiştir ve tüm teknolojiler alt başlıklar altında detaylı olarak verilmiştir.

Çalışmanın backend tarafı Java 21 ve Spring Boot 3.2 üzerine kurulmuştur. Frontend ve backend arasında haberleşmeyi sağlamak için Spring Web bağımlılığı kullanılarak RESTful API'lar oluşturulmuştur. Güvenlik geliştirmesinde Brute Force ataklarını önlemek için Rate Limiting sağlanmıştır.

Çalışmanın frontend tarafında ise Thymeleaf kullanılarak kullanıcılara önyüz deneyimi sağlanmıştır. Ekstra bir bağımlılığa ihtiyaç duyulmamıştır.

Uydu verilerinin alınması kısmında ise Sentinel-2 tercih edilmiştir. Sentinel-2 uydu görüntüleri ve coğrafi verilerle çalışmak için güçlü ve geniş bir sağlayıcıdır. Meteorolojik verilerin alınmasında ise OpenEO sağlayıcısından faydalanılmıştır.

3.3.1. Paket Yapısı

MVC yapısı, bir web uygulamasının farklı sorumluluklarına ayrılmasını sağlar ve kodun düzenli, bakımı kolay ve genişletmeye uygun olmasına katkıda bulunur.

- **Controller (Web uygulamasındaki istekleri karşılamak ve işlemekle sorumlu kontrolcü sınıfları):** Bu kısım, kullanıcı isteklerini karşılayan ve iş mantığına yönlendiren kontrolcü sınıflarını içerir.
- **Service (İş mantığı kurallarını uygulayan servis sınıfları):** Bu kısım, iş mantığı kurallarını uygulayan servis sınıflarını içerir. Bu sınıflar, genellikle iş mantığına ait operasyonları gerçekleştirir.
- **Model (Modelleri temsil eden sınıflar):** Bu kısım, proje içerisinde kullanılan modelleri temsil eden sınıfları içerir.
- **DTO (Verilerin transfer edilmesi için kullanılan sınıflar):** Bu kısım, farklı katmanlar arasında veri transferi için kullanılan sınıfları içerir.
- **Exception (Hata işleme ile ilgili sınıflar):** Bu kısım, hata işleme ve istisna yönetimi ile ilgili sınıfları içerir.
- **Config (Uygulama konfigürasyonu ile ilgili sınıflar):** Bu kısım, uygulama konfigürasyonu ile ilgili sınıfları içerir.
- **Util (Genel amaçlı yardımcı sınıflar):** Bu kısım, genel amaçlı yardımcı sınıfları içerir.
- **Client:** Bu kısım OpenEO ve Sentinel-2 uydusuna girilen koordinatlar ile istek sağlamak için tasarlanan sınıfları içerir.

Bu paket yapısı, MVC tasarım deseninin bir uygulamasını temsil eder ve genellikle büyük ve karmaşık web uygulamalarının geliştirilmesinde tercih edilir.

3.3.2. Java


Java, Sun Microsystems tarafından geliştirilen ve şu anda Oracle Corporation tarafından desteklenen bir programlama dilidir. 1996 yılında JDK(Java Development Kit) 1.0 ile ortaya çıkmıştır. "Write Once, Run Anywhere" (Bir kere yaz, her yerde çalıştır) prensibi ile bilinir. Java kodu bir kez yazılır ve farklı platformlarda çalışabilir.

Nesne yönelimli programlamayı destekler. Platform bağımsızdır ve sanal makine (Java Virtual Machine - JVM) üzerinde çalışır. Güvenli ve taşınabilir bir dil olmasıyla bilinir. Geniş kütüphane desteğine sahiptir.

Java programları genellikle Java Standard Edition (SE) veya Java Enterprise Edition (EE) kullanılarak geliştirilir. IDE (Integrated Development Environment) olarak Eclipse, IntelliJ IDEA ve NetBeans gibi araçlar sıkça kullanılır.

Java 21, 19 Eylül 2023'te piyasaya sürülen Java SE 21 platformunun referans uygulamasıdır. Java 21, Java 17'den sonra piyasaya sürülen ilk LTS (uzun vadeli destek) sürümüdür. LTS sürümleri, en az sekiz yıl boyunca güvenlik güncellemeleri ve kritik hata düzeltmeleri ile desteklenir. Java 21 ile gelen en iyi özellik sanal iş parçacıkları olmaktadır. Bu nedenle Java 21 tercih edilmiştir [44].

Java çalıştırma ortamı için IntelliJ IDEA tercih edilmiştir. IntelliJ IDEA (Integrated Development Environment), bir yazılım geliştirme ortamı (IDE) olarak bilinen ve JetBrains tarafından geliştirilen bir yazılım aracıdır. IntelliJ IDEA, özellikle Java, Kotlin, Groovy, Scala gibi JVM tabanlı diller için güçlü bir IDE olarak bilinir, ancak zamanla diğer dilleri ve teknolojileri de desteklemeye başlamıştır [45]. IDE üzerinden örnek proje oluşturma görüntüsü Şekil 3.5'de verilmiştir.



Şekil 3.5. IntelliJ idea örnek proje oluşturma

3.3.3. Spring Boot

Spring Boot, Spring Framework üzerine inşa edilmiş bir projedir. Uygulama geliştirmeyi hızlandırmak ve basitleştirmek için tasarlanmıştır. İlk kez 2014 yılında piyasaya sürüldü. Spring Boot, Pivotal Software (şu anda VMware) tarafından geliştirilmiştir. Spring Framework'ün bir parçasıdır.

Daha az konfigürasyon ile daha hızlı geliştirme sağlar. Uygulamanızı bağımsız bir web sunucusu olarak çalıştırmanıza olanak tanır (örneğin, Tomcat). Belirli bir yapıyı takip ederek kod miktarını azaltır.

Basit bir Maven veya Gradle projesi ile hızlı bir şekilde başlayabilirsiniz. Spring Boot uygulamaları genellikle modüler bir yapıya sahiptir. Veritabanı entegrasyonları, güvenlik, RESTful servis desteği gibi birçok özelliği içerir.

Bir Spring Boot projesi oluşturmak için Spring Initializer aracı kullanılabilir. Spring Boot uygulamaları genellikle Spring MVC veya Spring Webflux gibi modüllerle birlikte kullanılır [46].

Spring Boot 3.2, 23 Kasım 2023'te piyasaya sürülen Spring Boot'un en son sürümüdür. Spring Boot, Java 21 ile gelen sanal iş parçacıklarını desteklemektedir. Aşağıda Spring Boot bağımlılığı ile birlikte kullanmış olduğum bazı Spring bağımlılıkları verilmiştir.

Spring Web: Spring Web, Spring Framework'ün bir modülüdür ve web uygulamaları geliştirmek için gerekli temel özellikleri sağlar. Bu modül, HTTP protokolü üzerinden web isteklerini yönetmek, kontrolleri işlemek ve HTTP cevaplarını oluşturmak için kullanılır.

- Spring Web, gelen tüm HTTP isteklerini ele alarak uygun controller'a yönlendiren bir DispatcherServlet içerir.

- Controller sınıfları, gelen istekleri işleyen ve uygun cevapları oluşturan Java sınıflarıdır. Spring Web, MVC (Model-View-Controller) tasarım desenini takip eder.
- Spring Web, RESTful web hizmetleri oluşturmak için kullanılır. @RestController ve @RequestMapping gibi anotasyonlar, RESTful servislerin tanımlanmasını kolaylaştırır.
- Spring Web, web uygulamalarında kullanılan model ve görünüm (view) kavramlarını destekler. Model, verileri temsil ederken, görünüm kullanıcı arayüzünü temsil eder.
- Spring Web, HTTP metodlarına (GET, POST, PUT, DELETE vb.) uygun işlemleri gerçekleştirmek için anotasyonları sağlar. Örneğin, @GetMapping, @PostMapping, vb.

RESTful: REST (Representational State Transfer), web servislerinin tasarımı için bir mimari stildir. RESTful web servisleri, kaynakları temsil eden ve bu kaynaklarla etkileşime geçmek için HTTP protokolünü kullanan servislerdir.

REST, Roy Fielding tarafından 2000 yılında doktora tezi içinde tanımlanan bir mimari stildir. HTTP protokolüne dayalı olarak, dağıtık sistemler arasında etkileşimi tanımlar.

CRUD operasyonlarını gerçekleştirmek için HTTP metodları (GET, POST, PUT, DELETE) kullanılır.

REST, istemci-sunucu modeline dayanır. İstemci ve sunucu birbirinden bağımsızdır ve birbirleri hakkında bilgi sahibi değildirler.

REST, hafif ve esnek bir mimari stile sahiptir ve ölçeklenebilirliği artırır. Her bir istek, isteğin tüm bilgisini içerir ve sunucu tarafından herhangi bir önceki durum bilgisine ihtiyaç duymaz. Verilerin önbelleklenmesini ve tekrar kullanılmasını destekler. Rest örnek kullanımı Şekil 3.6'da verilmiştir.

```
@RestController
@RequestMapping("/api")
public class HelloController {

    @GetMapping("/hello")
    public String sayHello() { return "Hello, World!"; }
}
```

Şekil 3.6. RESTful örnek kullanımı

3.3.4. Thymeleaf

Çalışma, Thymeleaf üzerine kurulmuş, özellikle Spring ekosistemiyle uyumlu, sunucu taraflı HTML şablon motorudur. HTML dosyaları hem tasarımcıların hem de sunucu tarafında dinamik verilerle kolaylıkla zenginleştirilebilir. Yapısı sayesinde statik kaynak ve endpointlere güvenli bağlantı yönetimi sağlayarak aynı zamanda XSS saldırılarına karşı ek bir koruma katmanı sunar [47].

3.3.5. Sentinel-2

Sentinel-2, Avrupa Uzay Ajansı (ESA) tarafından yürütülen Copernicus Programı kapsamında geliştirilen bir uydu sistemidir. Bu sistem, özellikle kara yüzeylerinin gözlemi için tasarlanmış olup, çevresel izleme, tarımsal faaliyetlerin takibi, orman yönetimi, arazi örtüsü değişimlerinin belirlenmesi gibi birçok alanda yüksek çözünürlüklü optik görüntüler sağlamaktadır. Sentinel-2, çift uydudan (Sentinel-2A ve Sentinel-2B) oluşan bir yapıya sahiptir ve bu sayede Dünya yüzeyini ortalama beş günlük aralıklarla tarayarak kullanıcıya düzenli ve güncel veri sunar [48].

3.3.6. OpenEO

OpenEO, farklı uydu veri sağlayıcılarını ve büyük ölçekli uzamsal veri işleme sistemlerini tek bir standart API yapısı altında birleştiren açık kaynaklı bir platformdur. Bu platform, kullanıcıların Python, R, JavaScript veya REST API gibi farklı istemciler üzerinden uydu görüntüleri ve meteorolojik veriler üzerinde analiz gerçekleştirmelerini mümkün kılar. Açık standartlara dayalı bu mimari sayesinde, farklı veri merkezleriyle doğrudan iletişim kurulabilir ve karmaşık iş akışları bulut tabanlı altyapılar üzerinden yürütülebilir.

Ayrıca, OpenEO'nun sağladığı zaman serisi uyumluluğu, belirli dönemler arasındaki meteorolojik değişimleri inceleme olanağı tanımış; bu sayede hem bitki gelişimi hem de toprak nemi analizlerinde dışsal etmen olarak bu verilerin entegrasyonu sağlanmıştır [49].

3.4. Simülasyon Sonuçları

Bu bölümde, geliştirilen akıllı tarım analiz sisteminin doğruluğu, uygulanabilirliği ve literatüre katkısı test senaryoları üzerinden detaylı olarak değerlendirilmektedir. Uydu verileri ve meteorolojik bilgiler kullanılarak oluşturulan çift akışlı yapının özellikle kuraklık yönetimi, toprak nem tahmini ve bitki sağlığı takibi üzerindeki başarımı incelenmiştir. Testler, gerçek uydu görüntüleri ve çeşitli simülasyon senaryoları üzerinden yürütülmüş, sonuçlar hem grafiksel hem de sayısal olarak sunulmuş ve literatürdeki benzer çalışmalarla karşılaştırılmıştır.

Bu doğrultuda, aşağıdaki alt başlıklar altında sistemin işleyişine dair temel bileşenler, kullanılan veri kaynakları, uygulama mimarisi, modelleme süreci ve sonuçların değerlendirilmesi sistematik biçimde açıklanmıştır.

3.4.1. Kullanılan Veri Setleri

Simülasyon sürecinde, Sentinel-2 uydu görüntüleri ile meteorolojik veriler birincil kaynak olarak kullanılmıştır. Görseller, ESA Copernicus Hub üzerinden indirilen ve Türkiye'nin farklı bölgelerine ait 500 Sentinel-2 görüntüsünden oluşmaktadır. Seçilen görüntülerde bulut oranı %10'dan az olan, tarımsal faaliyetlerin yoğun olduğu Haziran-Eylül dönemine ait tarih aralığı esas alınmıştır. Her görüntü, kırmızı, yakın kızılötesi (NIR) ve SWIR bantlarında işlenmiş, NDVI ve NDMI indeksleri çıkarılmıştır.

Ek olarak, OpenEO platformu üzerinden aşağıdaki meteorolojik değişkenler temin edilmiştir:

- Günlük toplam yağış (mm)
- Hava sıcaklığı (°C)
- Rüzgâr hızı (m/s)
- Bağıl nem (%)

Veri setleri hem mekânsal hem zamansal çeşitliliğe sahip olacak şekilde oluşturulmuş, bu sayede modelin farklı iklim koşullarında ve arazi türlerinde geçerliliği test edilmiştir.

Testler için bir veri seti kullanılmıştır fakat 2 numaralı akışımızda bir makine öğrenmesi tahmini gerçekleşmediği için hazır bir veri seti ile değil anlık olarak alınan meteorolojik veriler kullanılmıştır. Veri setinin detayları Tablo 3.1'de verilmiştir.


Tablo 3.1. Önerilen yöntemde kullanılan veri setleri

Veri Seti	Tür	Boyut	Örnek Sayısı
Sentinel-2	Uydu Görüntüsü	2.3 GB	500 adet
OpenEO Meteorolojik	İklim Verisi		Gün sayısına göre anlık olarak çekilmektedir

3.4.2. Uygulama Mimarisi

Sistem, Java 21 ve Spring Boot 3.2 üzerine kurulmuş modüler bir yapıya sahiptir. Arka uçta RESTful API mimarisi ile servisler inşa edilmiştir. Kullanıcıdan alınan koordinatlar doğrultusunda hem Sentinel-2 verileri hem de OpenEO üzerinden çekilen meteorolojik veriler sistem tarafından analiz edilmiştir. Veri ön işleme ve model eğitimi adımları Python üzerinde gerçekleştirilmiş, RandomForestRegressor algoritması ile makine öğrenmesi yöntemi kullanılmıştır.


Ön yüzde ise Thymeleaf tabanlı HTML şablon motoru kullanılmış, kullanıcıların görselleştirilmiş tahminlere ulaşabilmeleri sağlanmıştır. Uygulama mimarisinin görselleştirilmiş hali Şekil 3.7’de verilmiştir.



Şekil 3.7. Önerilen yöntem uygulama mimarisi

3.4.3. Simülasyon

Simülasyon çıktıları, kullanıcıya sözel yorumlar olarak sunulmuştur. Aşağıda kullanıcının analizi neye göre yapacağını seçmeden önce örnek harita koordinat seçimi Şekil 3.8’de verilmiştir.



Şekil 3.8. Örnek konum seçim ekranı

Arayüz üzerinden yapılan konum seçiminden sonra, kullanıcının akış 1 yani uydu verileri üzerinden analiz yapma butonuna tıklaması üzerine enlem ve boylam bilgileri arka planda Sentinel-2'ye iletilecek ve Sentinel-2 üzerinden çekilen görüntü, RandomForestRegressor'a verildikten sonra, aşağıda örnek olarak verilen Şekil 3.9'da yer aldığı gibi bitki ve toprak nemi analizini elde edecektir.

Plant Health

Healthy: 84.04%, Medium: 15.51%, Poor: 0.45%

Soil Moisture Condition

Dry: 2.22%, Normal: 59.69%, Wet: 38.09%

Şekil 3.9. Uydu verileri analiz sonucu

Arayüz üzerinden yapılan konum seçiminden sonra kullanıcının akış 2 yani meteorolojik veriler üzerinden analiz yapma butonuna tıklaması üzerine enlem, boylam ve girilen gün sayısı bilgileri arka plan aracılığıyla OpenEO üzerinden çekilen meteorolojik veriler, basit bir algoritma ile yorumlandıktan sonra aşağıda örnek olarak Şekil 3.10'da yer alan analizdeki gibi kullanıcının girdiği gün sayısı içerisinde, bitki sağlığı için dikkat etmesi gereken bilgiler verilecektir.

Rainfall Analysis

A total of 18.9 mm of moderate rainfall was received. Additional irrigation may be required depending on plant type and development stage.

Temperature Analysis

Average temperatures (Avg. Max: 20.7°C, Avg. Min: 11.3°C) were generally within the optimum ranges for plant development. Plant growth rates may have been supported.

Humidity Analysis

Average relative humidity is at a stable level, the risk of disease may be low.

Wind Analysis


The number of windy days is high (8 days). Wind erosion and plant damage should be taken into consideration, and windbreak measures should be taken if necessary.

Şekil 3.10. Meteorolojik veri analiz sonucu

3.4.3. Elde Edilen Sonuçlar ve Karşılaştırılması

Uygulamanın performans testlerinin ötesinde, akıllı tarım ve kuraklık analizi özelliklerinin test edilmesi, uygulamanın işlevselliği ve çıktıların doğruluğu açısından kritik bir öneme sahiptir. Bu testlerin gerçekleştirilmesi, uygulamanın akıllı tarım ve kuraklık analizi özelliklerinin doğruluğunu ve güvenilirliğini sağlamak adına önemli bir adımdır. Çıktıların doğruluğu, tarım ve su kaynaklarının yönetimi açısından kritik bir rol oynayacağından, bu testlerin titizlikle gerçekleştirilmesi önemlidir. Elde edilen sonuçlar, uygulamanın bu analizlerde ne kadar başarılı olduğunu belirleyerek, kullanıcıların güvenle bu verilere dayanmasını sağlamaktadır. Bu kapsamda gerçekleştirilecek olan test sonucu sadece akış 1 için ele alınmıştır. Çünkü akış 1 yani uydu verileri üzerinden RandomForestRegressor ile yapılan yöntem üzerinde kullanımı gerçekleştirilmiş ve test süreci sağlanmıştır. Akış 2 yani meteorolojik verilerden elde edilen tahminler daha çok kullanıcıyı tarım üzerinde yönlendirme ve verimliliği arttırmayı hedefleyerek yorumlamaya dayalı bir akıştır, bu adımda yorumlamanın sağladığı faydaları elde edebilmek için uzun süre kullanım ve kullanıcı dönüşlerine ihtiyaç vardır.

Akış 1 için RandomForestRegressor Sentinel-2 uydu görüntülerinden çıkarılan NDVI ve NDMI öznitelikleri kullanılarak 500 örnek görüntüyü test verisi olarak değerlendirilmiştir. Yapılan testler Türkiye haritası üzerinde Sentinel-2 uydu görüntüsünden alınan veriler ile elde edilmiştir. Test sonucunda, toprak nemi tahmininde %86, bitki sağlığı tahminlerinde ise %88 düzeyinde başarı göstererek saha koşullarında güvenilir tahminler ürettiğini ortaya koymuştur. Sonuçlar aşağıda Şekil 3.11’de verilmiştir.



Şekil 3.11. RandomForestRegressor sonuçları

Sentinel-2 uydu verileri kullanılarak gerçekleştirilen ve RandomForestRegressor algoritması ile desteklenen akış 1 kapsamındaki akıllı tarım analizine ait sonuçlar, güncel literatürde yer alan benzer çalışmalarla karşılaştırmalı olarak Tablo 3.2’de sunulmuştur. Bu tabloda, önerilen yöntemin performansı, aynı ya da benzer veri kaynaklarını kullanan farklı modellerle yapılan çalışmalarla birlikte değerlendirilmiştir.

Tablodan da görülebileceği üzere, bu tez çalışmasında uygulanan yöntem, yalnızca 500 uydu görüntüsünden oluşan sınırlı bir veri kümesiyle test edilmesine rağmen, elde ettiği performansla dikkat çekmektedir. Bu durum, özellikle çalışmanın verilerin bölgeye özgü seçilmesi ve NDVI ile NDMI gibi tarımsal anlamda güçlü özneliliklerin dikkatli biçimde yapılandırılması sayesinde mümkün olmuştur. Literatürde yer alan benzer çalışmaların çoğunlukla binlerce örnek içeren veri kümeleriyle çalışmasına karşın, bu tezde kullanılan daha küçük ölçekli ancak nitelikli veri seti, hem işlem verimliliği hem de yorumlanabilirlik açısından avantaj sağlamıştır.

Ayrıca, Sentinel-2 gibi yüksek çözünürlüklü uydu görüntülerinin kullanılması, özellikle bitki sağlığı ve toprak nemi gibi tarım için kritik değişkenlerin doğru biçimde modellenmesini kolaylaştırmıştır. Bu bağlamda, %86–88 arası doğruluk değerine ulaşılması, yöntemin saha koşullarında pratik olarak da uygulanabilir olduğunu göstermektedir. Elde edilen sonuçlar, veri kalitesi ve algoritma seçiminin model başarısındaki etkisini bir kez daha ortaya koymakta, sınırlı veri ile etkili analizlerin yapılabileceğini göstermesi bakımından literatüre değerli bir katkı sunmaktadır.

Tablo 3.2. Önerilen yöntemin literatür ile karşılaştırması

Referans	Veri Kaynağı	Kullanım Alanları	Doğruluk
Shokati ve ark. [50]	Sentinel-2 görüntüleri	RandomForestRegressor	%49
Shokati ve ark. [50]	Landsat-8/9 görüntüleri	RandomForestRegressor	%66
Hassan-Esfahani ve ark. [51]	Hiperspektral görüntüler	Yapay Sinir Ağı	%77
Önerilen yöntem	Sentinel-2 görüntüleri	RandomForestRegressor	%86-88

4. KURAKLIK RISKİ, GIDA VE SU GÜVENLİĞİ RISK DEĞERLENDİRMESİ İÇİN DERİN ÖĞRENME TABANLI MODELLER

Tarımsal üretimin sürdürülebilirliği, kuraklık, gıda güvenliği ve su güvenliği gibi çevresel ve insani risk faktörleri ile doğrudan ilişkilidir. Bu bağlamda, toprak ve iklim verilerine dayalı olarak geliştirilen yapay zekâ modelleri, kritik karar destek sistemleri için önemli bir araç haline gelmiştir. Bu bölümde, farklı veri setleri ve derin öğrenme mimarileri kullanılarak kuraklık riski, su güvenliği ve gıda güvenliği uygunluğu ayrı ayrı ele alınmış; her bir başlık altında geliştirilen modellerin performansları, doğruluk oranları ve mekânsal tahmin kabiliyetleri detaylı şekilde değerlendirilmiştir. Elde edilen bulgular, tarımsal karar destek sistemlerinin hem doğruluk hem de coğrafi hassasiyet açısından ne derece etkin olabileceğini ortaya koymaktadır. Bu başlık altında yapılan tüm çalışmalar ve elde edilen sonuçlar Google Colaboratory üzerinde gerçekleştirilmiştir [52]. Programlama dili olarak Python kullanılmıştır [53]. Elde edilen veri setleri Kaggle üzerinden alınarak csv dosyası olarak sentezlenmiştir [54].

4.1. Kuraklık Riski

Kuraklık, tarımsal üretim üzerindeki en kritik doğal tehditlerden biri olarak kabul edilmekte olup; bitki gelişimi, toprak verimliliği ve genel ekosistem dengesi üzerinde doğrudan olumsuz etkilere sahiptir. Bu nedenle, tarım alanlarında kuraklık riskinin önceden öngörülmesi ve mekânsal olarak değerlendirilmesi, kaynak yönetimi ve üretim planlaması açısından stratejik bir öneme sahiptir.

4.1.1. Kuraklık Riski Veri Seti

Bu çalışmada kuraklık riski tahmini amacıyla kullanılan veri seti, Amerika Birleşik Devletleri'ne ait çeşitli tarım alanlarından toplanmış toprak morfolojisi, eğim, yönelme ve arazi kullanım tiplerini içeren çok boyutlu çevresel verileri kapsamaktadır. Veri setinde her satır bir tarım arazisine karşılık gelmektedir. Veriler içerisinde, coğrafi konum bilgilerini içeren enlem ve boylam değişkenlerinin yanı sıra, rakım gibi topoğrafik parametreler de yer almaktadır.

Eğim bilgisi, sekiz ayrı yön için yüzdelik değerlerle verilmiş olup, arazinin fiziksel özelliklerine ilişkin detaylı bir bakış sunmaktadır. Ayrıca yönelme değişkenleri ile arazinin güneşe maruz kalma açısı yönsel olarak temsil edilmiştir. Bunun yanında, arazi tipi gibi değişkenler aracılığıyla alanın su yüzeyi, ormanlık alan, kentsel yapılaşma ve kültür arazisi oranları detaylandırılmıştır.

Modelde hedef değişken olarak toprak kalitesi sütunu seçilmiştir. Bu değişken, USDA tarafından tanımlanan toprak kalitesi sınıflarına karşılık gelen ve tarımsal üretkenlik bağlamında kuraklık riskiyle ilişkili olduğu kabul edilen sınıfları içermektedir. Toprak kalitesi değişkeni, 0 ile 2 arasında değişen kategorik değerlere sahiptir ve sınıflandırma modeli bu değişkenin tahmini üzerine kurulmuştur.

Modelleme sürecinde, yalnızca Toprak kalitesi 0 değişkeni hedef olarak belirlenmiş; Giriş değişkenlerinin tamamı standartlaştırılmış ve böylece farklı ölçeklerdeki değişkenlerin model üzerindeki etkisi dengelenmiştir.

Bu veri seti, kuraklık riskinin hem çevresel hem de coğrafi bağlamda modellenenbilmesine olanak sağlayan zengin bir yapıya sahiptir ve bu yönüyle çalışma kapsamında geliştirilen derin öğrenme modeline sağlam bir temel oluşturmuştur. Veri setinin yapısı Tablo 4.1’de verilmiştir.

Tablo 4.1. Kuraklık riski veri seti

Değişken Grubu	Değişkenler	Açıklama	Türü
Konumsal bilgiler	Enlem ve boylam	Tarım alanına ait enlem ve boylam bilgileri	Sayısal
Topoğrafik özellikler	Rakım	Arazi yüksekliği	Sayısal
Eğim özellikleri	Eğim	Arazinin yön doğrultusundaki eğim yüzdeleri	Sayısal
Yönelme	Yönelim	Arazinin yönelimi	Sayısal
Arazi kullanım türleri	Arazi tipi	Arazi tipleri	Sayısal
Hedef değişkenler (Toprak kalite endeksi)	Toprak kalitesi	Toprak kalite sınıfları	Kategorik

4.1.2. DroughtNet-X Modeli


Bu çalışmada, kuraklık riski sınıflandırması amacıyla **DroughtNet-X** adı verilen özel bir derin öğrenme modeli geliştirilmiştir. Model, toprak, iklim ve coğrafi konum gibi çevresel ve topoğrafik özellikleri giriş verisi olarak alarak, her bir örneği kuraklık duyarlılığı açısından sınıflandırmakta ve bu doğrultuda risk seviyelerini tahmin etmektedir.

DroughtNet-X, çok katmanlı yapay sinir ağı (MLP) mimarisiyle tasarlanmış olup, aşağıdaki bileşenlerden oluşmaktadır:

- Giriş katmanı, modelin öğrenmesini sağlayacak çok sayıda çevresel girdiyi alır.
- İki adet gizli katman, her biri 128 nörondan oluşur ve bu katmanlarda Batch Normalization, ReLU aktivasyon fonksiyonu ve Dropout düzenleme yöntemleri uygulanmıştır. Bu sayede modelin aşırı öğrenme (overfitting) yapması engellenmiş, öğrenme süreci dengelenmiştir.


- Çıkış katmanı, yedi farklı kuraklık sınıfını temsil eden nöronlardan oluşmakta ve çok sınıflı sınıflandırma problemleri için uygundur.

Modelin eğitimi sırasında Adam optimizasyon algoritması, 0.0008 öğrenme oranı (learning rate) ve CrossEntropyLoss kayıp fonksiyonu kullanılmıştır. Model, 250 epoch boyunca eğitilmiş ve eğitim sürecindeki kayıp değerleri takip edilmiştir. Modelin katmanları Şekil 4.1’de verilmiştir.



Şekil 4.1. DroughtNet-X model katmanları

Eğitim süreci sonunda elde edilen düşük kayıp ve yüksek doğruluk değerleri, modelin hedeflenen sınıflandırma görevini başarıyla gerçekleştirdiğini göstermiştir. Modelin mimarisi aşağıda Şekil 4.2’de verilmiştir.




Şekil 4.2. DroughtNet-X model mimarisi

Ayrıca, modelin başarımı yalnızca doğruluk oranı ile değil, aynı zamanda makro F1 skoru, hassasiyet ve duyarlılık gibi kapsamlı değerlendirme metrikleri ile analiz edilmiştir. Eğitim ve test sürecine ilişkin kayıp grafiği ile birlikte, sınıflandırma sonuçları interaktif harita üzerinde de görselleştirilmiştir.

4.1.3. DroughtNet-X Eğitim Performansı ve Doğruluk Değerlendirmesi

Kuraklık riski sınıflandırması için geliştirilen DroughtNet-X modeli, yüksek doğruluk oranı ile başarılı sonuçlar vermiştir. Model, eğitim süreci tamamlandıktan sonra test verisi üzerinde yapılan değerlendirmede **%81.21** doğruluk oranına ulaşmıştır. Bu sonuç, DroughtNet-X modelinin

karmaşık çevresel verilerden anlamlı örüntüler öğrenme kapasitesine sahip olduğunu göstermektedir. Modelin eğitim sürecinde elde edilen eğitim kayıp grafiği aşağıda Şekil 4.3’de verilmiştir.




Şekil 4.3. DroughtNet-X eğitim kayıp grafiği

Toprak kalitesine ilişkin SQ0 (Toprak Kalitesi 0) sınıflandırması için geliştirilen derin öğrenme tabanlı modelin performansı değerlendirilmiştir. Model, test verisi üzerinde %81.21 doğruluk oranı elde ederek genel olarak başarılı bir tahmin gücüne sahip olduğunu göstermiştir. Tablo 4.2’de verilen değerler, modelin sınıflar arasında dengeli bir şekilde tahmin yapma kapasitesine sahip olduğunu, ancak bazı sınıflarda kısmi karışmaların meydana geldiğini göstermektedir. Şekil 4.4’de verilen karmaşıklık matrisi, modelin her bir sınıf için tahmin doğruluğunu detaylı biçimde ortaya koymaktadır. Özellikle sınıf “0” ve sınıf “2” için modelin tahmin başarısı dikkat çekici düzeydedir. Örneğin; 304 örnek doğru şekilde sınıf “0” olarak tahmin edilmiştir. Ancak sınıf “1” başarı görece daha düşüktür. Model, bu sınıfın 45 örneğini doğru tahmin ederken, 36 örneği sınıf 2 ile 10 örneği ise sınıf 0 ile karıştırmıştır. Bu durum, sınıf 1’in özellik uzayında diğer sınıflarla daha fazla örtüşme gösterdiğini düşündürmektedir.

Tablo 4.2. DroughtNet-X model metrikleri

Doğruluk	Hassasiyet	Duyarlılık	F1 Skoru
%81.21	%74	%73	%73



Şekil 4.4. DroughtNet-X model karmaşıklık matrisi

Modelin başarımı, aynı veri seti üzerinde test edilen bazı geleneksel makine öğrenmesi algoritmaları ile karşılaştırılmıştır. Bu algoritmalar ve elde edilen doğruluk oranları Lojistik Regresyon %78.14, K-En Yakın Komşu (KNN) %77.01'dir. Bu sonuçlar, DroughtNet-X modelinin diğer yöntemlere kıyasla daha güçlü bir sınıflandırma performansı sunduğunu ortaya koymaktadır. Derin yapısı ve düzenleme teknikleri sayesinde model hem doğruluk hem de sınıf ayrımı açısından daha tutarlı ve güvenilir sonuçlar üretmiştir. Üretilen modelin makine öğrenmesi yöntemleri ile karşılaştırması Tablo 4.3'de verilmiştir.

Tablo 4.3. DroughtNet-X modelinin makine öğrenmesi yöntemleriyle karşılaştırması

Yöntem	Veri Kaynağı	Kullanım Alanı	Doğruluk
Lojistik Regresyon	ABD tarım verisi	Kuraklık riski	%78.14
K-En Yakın Komşu	ABD tarım verisi	Kuraklık riski	%77.01
DroughtNet-X	ABD tarım verisi	Kuraklık riski	%81.21

4.1.4. Kuraklık Riski Sonuçlarının Yorumlanması


Modelden elde edilen sınıflandırma çıktıları, yalnızca sayısal doğruluk analizleri ile sınırlı kalmayıp mekânsal olarak da görselleştirilmiştir. Bu amaçla, test verisi üzerindeki örneklerin

coğrafi koordinatları kullanılarak interaktif bir harita oluşturulmuş; her bir nokta model tarafından tahmin edilen kuraklık sınıfına göre renklendirilmiştir.

Harita, test veri setine ait her bir örneği temsil eden dairesel işaretleyicilerden oluşmaktadır. Bu işaretleyiciler, SQ tahmin sınıfına göre farklı renklerle kodlanmıştır. Renk dağılımı, düşük riskten yüksek riske kadar sırasıyla **yeşil**, **sarı**, **turuncu** tonlarında görselleştirilmiştir. Böylece, kullanıcıların harita üzerinde risk sınıflarını kolayca ayırt edebilmesi sağlanmıştır.

Harita üzerinde yapılan gözlemler, modelin çeşitli bölgelerde benzer özellikler gösteren noktaları tutarlı şekilde aynı risk grubuna atadığını göstermektedir. Bu durum, modelin mekânsal genelleme yeteneğini ortaya koymakta; dolayısıyla coğrafi temelli karar destek sistemlerinde kullanılabilirliğini desteklemektedir.

Aşağıda Şekil 4.5’de test verilerine ait mekânsal kuraklık sınıflandırma haritası örnek olarak sunulmuştur. Bu tür görselleştirmeler, özellikle bölgesel planlama ve tarımsal risk analizleri açısından pratik katkılar sağlayabilecek niteliktedir.



Şekil 4.5. DroughtNet-X örnek çıktısı

4.2. Su Güvenliği

Tarımda sürdürülebilir üretimin temel bileşenlerinden biri olan su güvenliği, bitki gelişimini doğrudan etkileyen çevresel koşulların başında gelmektedir. Su kaynaklarının azalması ve iklim değişikliğiyle birlikte artan belirsizlikler, tarımsal üretim süreçlerinde su güvenliği riskinin doğru bir şekilde analiz edilmesini zorunlu kılmaktadır.

4.2.1. Su Güvenliği Veri Seti ve Özellikleri

Su güvenliği riski tahmini için kullanılan veri seti, farklı coğrafi bölgelerdeki tarım alanlarına ilişkin çevresel ve üretim temelli verileri içermektedir. Veri seti, her bir tarım alanına ait toprak, iklim, sulama ve bitki sağlığı gibi pek çok değişkeni kapsamaktadır. Toplam 22 sütundan oluşan veri setinde toprak nemi, yağış, bitki örtüsü endeksi, sıcaklık, nem, güneş ışığı saatleri ve toprak pH değeri gibi değişkenler, su varlığı ve bitki gelişimi açısından doğrudan anlam taşıyan başlıca parametrelerdir.

Veri setinde doğrudan bir hedef değişken (etiket) bulunmadığı için, su güvenliği riski belirli çevresel eşiklere göre türetilmiştir.

Bu kapsamda uygulanan kural tabanlı sınıflandırma yaklaşımı şu şekildedir:

- **Yüksek Risk (2):** Toprak nemi %20'nin altında veya yağış miktarı 50 mm'nin altında veya NDVI değeri 0,4'ün altında olan alanlar
- **Orta Risk (1):** Toprak nemi %20–30 arasında veya yağış miktarı 50–100 mm arasında veya NDVI 0,4–0,6 arasında olan alanlar
- **Düşük Risk (0):** Yukarıdaki eşiklerin dışında kalan, su yönünden daha elverişli koşullara sahip alanlar

Bu kurallar; su stresinin bitki gelişimi üzerindeki etkisini gösteren bilimsel bulgular, NDVI göstergelerinin biyokütle ile ilişkisi ve yağış-toprak nemi etkileşimi göz önünde bulundurularak tanımlanmıştır. Böylece modelin, tekil değişkenler yerine çoklu faktörlere dayalı bir risk değerlendirmesi yapması hedeflenmiştir.

Veri setinde ayrıca enlem ve boylam sütunları bulunduğundan, model çıktılarının mekânsal olarak haritalanması da mümkün hale gelmiştir. Bu özellik, yalnızca doğruluk ölçümlerine değil, aynı zamanda coğrafi risk dağılım analizlerine de olanak sağlamaktadır. Veri setinin yapısı Tablo 4.4'de verilmiştir.

Tablo 4.4. Su güvenliği veri seti


Değişken Grubu	Değişkenler	Açıklama	Türü
Konumsal bilgiler	Enlem ve boylam	Tarım alanlarının konumsal bilgileri	Sayısal
İklimsel özellikler	İklim bilgileri	Su döngüsünü etkileyen temel iklimsel değişkenler	Sayısal
Toprak özellikleri	Toprak değerleri	Toprak nemi ve kimyasal yapısı ile ilgili özellikler	Sayısal
Bitki ve gelişim göstergeleri	Bitki endeksleri	Bitki sağlığı ve gelişim düzeyine ilişkin göstergeler	Sayısal
Tarım yönetimi bilgileri	Tarım alanında kullanılan yöntemler	Yetiştiricilikte uygulanan tarımsal yöntem bilgileri	Sayısal

Zaman bilgileri	Zaman verileri	Üretim süreci ile ilgili tarihsel veriler	Tarihsel
Hedef değişken	Su güvenlik riski	Kurallara dayalı olarak oluşturulan su güvenliği sınıfı	Kategorik

4.2.2. WS-RiskNet Modeli

Bu çalışmada su güvenliği risk düzeylerinin tahmini amacıyla geliştirilen model, **WS-RiskNet** olarak adlandırılmıştır. Model, tarımsal üretimi etkileyen çevresel parametreler üzerinden sınıflandırma yapabilen, çok katmanlı yapay sinir ağı (ANN) mimarisi ile tasarlanmıştır.

Giriş katmanında, tarımsal anlamda kritik öneme sahip sekiz değişken – toprak nemi, yağış miktarı, sıcaklık, bağıl nem, NDVI (Normalized Difference Vegetation Index), güneşlenme süresi, enlem ve boylam ve toprak pH değeri – modelin girdilerini oluşturmaktadır. WS-RiskNet, iki adet gizli katmandan oluşmakta olup her bir katmanda doğrusal olmayan ilişkileri öğrenebilme yeteneğini artırmak amacıyla ReLU (Rectified Linear Unit) aktivasyon fonksiyonu tercih edilmiştir. Modelin çıkış katmanı ise, tarım alanlarının su güvenliği açısından düşük, orta ve yüksek risk gruplarına ayrılmasını sağlayacak şekilde tasarlanmıştır. Modelin diyagramı aşağıda Şekil 4.6’da verilmiştir.




Şekil 4.6. WS-RiskNet model diyagramı

Sonuç olarak WS-RiskNet, çevresel verilerden yararlanarak tarımsal bölgelerdeki su güvenliği riskini güvenilir biçimde tahmin edebilen, yalın ama etkili bir makine öğrenmesi yaklaşımı sunmaktadır. Model çıktıları, risk haritalarının görsel olarak sunulması ve önleyici su yönetimi stratejilerinin geliştirilmesi gibi uygulamalarda karar vericilere önemli ölçüde destek sağlamaktadır.

4.2.3. WS-RiskNet Eğitim Performansı ve Doğruluk Değerlendirmesi

WS-RiskNet modeli, eğitim süreci sonucunda yüksek doğruluk oranıyla başarılı bir sınıflandırma performansı sergilemiştir. Modelin test verileri üzerindeki doğruluk oranı **%92** olarak hesaplanmıştır. Bu sonuç, modelin çevresel değişkenlere dayalı su güvenliği risk sınıflandırmasında etkili bir şekilde genelleme yapabildiğini göstermektedir. Modelin eğitim sürecinde elde edilen eğitim kayıp grafiği aşağıda Şekil 4.7’de verilmiştir.




Şekil 4.7. WS-RiskNet eğitim kayıp grafiği

Modelin su güvenliği riski sınıflandırma başarısı Şekil 4.8’de sunulan karmaşıklık matrisi ve temel performans metrikleri ile değerlendirilmiştir. Üç sınıflı (Düşük, Orta, Yüksek risk) problem için oluşturulan model, test verisinde %92 doğruluk oranı elde etmiştir. Bu sonuç, modelin genel sınıflandırma kabiliyetinin oldukça yüksek olduğunu göstermektedir. Tablo 4.5’de verilen metrikler, modelin her bir sınıfa karşı dengeli ve tutarlı bir başarı sergilediğini ortaya koymaktadır. Karmaşıklık matrisi incelendiğinde, modelin “Yüksek risk” sınıfını ayırt etmede son derece başarılı olduğu (47 doğru sınıflama) görülmektedir. Aynı şekilde “Orta risk” sınıfında da 31 doğru tahmin yapılmış, yalnızca 5 örnek diğer sınıflara kaymıştır. “Düşük risk” sınıfında ise tüm tahminler doğru

olarak sınıflandırılmıştır. Bu durum, modelin özellikle su güvenliği açısından kritik olan yüksek riskli alanları doğru tespit etmede güçlü bir genel performansa sahip olduğunu göstermektedir.

Tablo 4.5. WS-RiskNet model metrikleri

Doğruluk	Hassasiyet	Duyarlılık	F1 Skoru
%92	%88	%92	%90



Şekil 4.8. WS-RiskNet model karmaşıklık matrisi

Karşılaştırmalı analiz kapsamında, aynı veri seti üzerinde klasik makine öğrenmesi algoritmaları da değerlendirilmiştir. **Lojistik Regresyon** modeli %84 doğruluk oranı elde ederken, **K-En Yakın Komşu (KNN)** algoritması %83 doğrulukla sınıflandırma yapabilmektedir. Bu kıyaslamalar, WS-RiskNet modelinin diğer geleneksel yöntemlere kıyasla daha üstün bir performans sunduğunu ortaya koymaktadır.

Elde edilen bu sonuçlar, WS-RiskNet modelinin su güvenliği riski öngörüsünde kullanılabilirliğini desteklemekte ve modelin tarımsal karar destek sistemlerine entegre edilebilir yapıda olduğunu göstermektedir. Üretilen modelin makine öğrenmesi yöntemleri ile karşılaştırması Tablo 4.6’da verilmiştir.

Tablo 4.6. WS-RiskNet modelinin makine öğrenmesi yöntemleriyle karşılaştırması


Yöntem	Veri Kaynağı	Kullanım Alanı	Doğruluk
Lojistik Regresyon	Tarım verisi	Su güvenliği riski	%84
K-En Yakın Komşu	Tarım verisi	Su güvenliği riski	%83
WS-RiskNet	Tarım verisi	Su güvenliği riski	%92

4.2.4. Su Güvenliği Sonuçlarının Yorumlanması

Modelin tahmin çıktıları, mekânsal analizlerle desteklenerek görselleştirilmiştir. Su güvenliği riskine ilişkin sınıflandırma sonuçları, veri setinde yer alan enlem ve boylam bilgilerle eşleştirilerek bir interaktif harita üzerinde temsil edilmiştir. Bu kapsamda, WS-RiskNet modeli tarafından tüm gözlemler için yapılan tahminler doğrultusunda her nokta, risk düzeyine göre renklendirilmiş daire simgeleriyle gösterilmiştir.

Renk yelpazesi, düşük risk için **yeşil**, orta risk için **turuncu**, yüksek risk için ise **kırmızı** olacak şekilde tanımlanmıştır. Bu görsel ayrım, kullanıcıların mekânsal risk dağılımını kolaylıkla analiz edebilmesini sağlamıştır. Harita üzerinde özellikle yağış miktarı ve toprak nemi düşük bölgelerde kırmızı renklerin yoğunlaştığı gözlemlenmiş; bu da modelin çevresel değişkenlere duyarlılığını göstermektedir.

Bu görselleştirme yöntemi, modelin yalnızca sayısal başarımını değil aynı zamanda mekânsal doğruluk ve karar destek potansiyelini de ortaya koymaktadır. Görsel çıktılar, tarımsal su yönetimi açısından kritik bölgelerin önceliklendirilmesine olanak tanımış, karar vericiler için sezgisel ve uygulamaya yönelik veri sunmuştur. Aşağıda şekil 4.9’da test verilerine ait mekânsal su güvenliği sınıflandırma haritası örnek olarak sunulmuştur.



Şekil 4.9. WS-RiskNet örnek çıktısı

4.3. Gıda Güvenliği

Gıda güvenliği, sürdürülebilir tarımsal üretimin sağlanmasında temel belirleyicilerden biridir. İklimsel koşullar, toprak özellikleri, sulama yöntemleri ve çevresel faktörler, ürün verimini doğrudan etkilemektedir. Bu nedenle, veri odaklı yapay zekâ yöntemleriyle ürün verimini modellemek, potansiyel gıda risklerinin öngörülmesinde stratejik bir rol oynamaktadır.

Bu çalışmada, çeşitli tarımsal ve çevresel parametrelere dayalı olarak ürün verimini tahmin etmek ve bu tahmin üzerinden gıda güvenliği düzeyini değerlendirmek amaçlanmıştır. Uygulama kapsamında uydu destekli ölçümler ve tarımsal girdi bilgileri birleştirilerek derin öğrenme tabanlı bir yaklaşım geliştirilmiştir.

4.3.1. Gıda Güvenliği Veri Seti ve Özellikleri

Bu çalışmada, Kolombiya'daki kakao üretimine ilişkin mekânsal, iklimsel ve tarımsal parametreleri içeren bir veri seti kullanılmıştır. Veri seti, 2019–2023 yılları arasındaki beş farklı yıla ait ölçümleri içermekte olup her yıl için ortalama ve standart sapma değerleriyle birlikte toplanmıştır. Veriler, NASA ve benzeri uzaktan algılama kaynaklarına dayalı olarak hazırlanmış ve tarım arazilerine ait koordinat bazlı bilgilerle zenginleştirilmiştir.

Veri seti içerisinde her yıl için aşağıdaki başlıca özellikler yer almaktadır:

- **İklimsel Veriler:** Yağış miktarı, yüzey güneş radyasyonu, bağıl nem, rüzgâr hızı, maksimum ve minimum sıcaklıklar

- **Toprak Nem Durumu:** Veriler ile temsil edilen yüzey ve kök nem düzeyleri.
- **Coğrafi Bilgiler:** Enlem, boylam ve rakım bilgileri
- **Hedef Değişken:** Arazinin kakao üretimi açısından uygunluk düzeyini temsil eden sınıflandırılmış çıktı (gıda güvenliği bağlamında değerlendirilmiştir)

Veri setindeki uygunluk sütunu, modelin tahmin edeceği hedef değişken olarak belirlenmiş ve kakao üretimi açısından alanın uygunluk düzeyini temsil etmektedir. Bu değişken, dolaylı olarak gıda güvenliği risk seviyesini ifade etmektedir. Böylece gıda güvenliğini etkileyen çevresel ve iklimsel faktörler, modelleme sürecine entegre edilmiştir. Veri setinin yapısı Tablo 4.7’de verilmiştir.

Tablo 4.7. Gıda güvenliği veri seti


Değişken Grubu	Değişkenler	Açıklama	Türü
Konumsal bilgiler	Enlem ve boylam	Araziye alanına ait enlem ve boylam bilgileri	Sayısal
Topoğrafik özellikler	Rakım	Arazi yüksekliği	Sayısal
Alan özellikleri	Büyüklik	Tarım yapılan alanın hektar cinsinden büyüklüğü	Sayısal
Ortalama iklimsel veriler	Meteorolojik veri	Ortalama sıcaklık, rüzgâr hızı, nem ve güneş ışıınımı değerleri	Sayısal
Toprak ve nem göstergeleri	Toprak ve nem verileri	Toprak nemine ilişkin katmanlara göre ortalama değerler	Sayısal
Yağış göstergeleri	Yağış kalitesi	Toplam yağış miktarı	Sayısal
Standart sapma iklimsel veriler	Meteorolojik veri	Meteorolojik değişkenlerin sapması	Sayısal
Hedef değişken	Uygunluk Derecesi	Tarım arazisinin kakao üretimine uygunluk düzeyi	Kategorik

4.3.2. FoodNet-C Modeli

Bu çalışmada, gıda güvenliği risk düzeylerinin öngörülmesine yönelik olarak **FoodNet-C** adlı bir derin öğrenme modeli geliştirilmiştir. Model, tarım arazilerinin kakao üretimi açısından uygunluk seviyelerini, çevresel ve iklimsel değişkenlere dayanarak sınıflandırmayı hedeflemektedir.


FoodNet-C modeli, çok katmanlı yapay sinir ağı (DNN) mimarisiyle yapılandırılmıştır. Modelin giriş katmanında; toprak nem profilleri, yüzey ışıınımı, ortalama sıcaklıklar, nem değerleri ve rakım gibi çeşitli fiziksel ve iklimsel parametreleri içeren 10’a yakın giriş değişkeni

bulunmaktadır. Modelin ara katmanlarında ReLU aktivasyon fonksiyonu kullanılarak doğrusal olmayan örüntülerin öğrenilmesi sağlanmıştır. Aşırı öğrenmenin önüne geçilmesi amacıyla dropout katmanları da eklenmiştir. Modelin katmanları Şekil 4.10’da verilmiştir.



Şekil 4.10. FoodNet-C model katmanları

Model çıktısı, kakao üretimine uygunluk düzeyini “yüksek”, “orta” ve “düşük” olmak üzere üç sınıfa ayırmaktadır. Sınıflar arasında gözlemlenen dengesizliklerin model performansını etkilemesini önlemek adına ağırlıklandırılmış bir kayıp fonksiyonu uygulanmıştır. Eğitim süreci sonunda modelin başarımı; doğruluk oranı, sınıflandırma raporu ve çeşitli metriklerle değerlendirilmiştir. Modelin mimarisi aşağıda Şekil 4.11’de verilmiştir.




Şekil 4.11. FoodNet-C model mimarisi

Son aşamada, modelin tahmin ettiği uygunluk kategorileri, coğrafi koordinatlara dayalı olarak haritalandırılmış ve farklı sınıflar için renk kodlu işaretleyicilerle görsel olarak sunulmuştur. Böylece karar vericiler, mekânsal düzeyde gıda güvenliği risklerini değerlendirerek stratejik tarım planlaması yapabilmektedir.

4.3.3. FoodNet-C Eğitim Performansı ve Doğruluk Değerlendirmesi

FoodNet-C modeli, kakao üretim alanlarının uygunluk düzeyini sınıflandırma görevinde başarılı bir performans sergilemiştir. Eğitim süreci sonunda model, test verileri üzerinde **%84.11** doğruluk oranı elde etmiştir. Modelin eğitim sürecinde elde edilen eğitim kayıp grafiği aşağıda Şekil 4.12’de verilmiştir.




Şekil 4.12. FoodNet-C eğitim kayıp grafiği

Tablo 4.8’de verilen metrikler, modelin her bir sınıfta benzer doğrulukla tahmin yaptığını ve dengesiz sınıf dağılımından etkilenmeden genel bir denge sağladığını göstermektedir. Şekil 4.13’de sunulan karmaşıklık matrisi incelendiğinde, modelin çoğu veriyi doğru sınıflandırdığı görülmektedir. Özellikle “Orta Uygunluk” sınıfına ait 2752 örnekten 2520’si doğru şekilde tahmin edilmiştir. Benzer şekilde, “Yüksek Uygunluk” sınıfına ait 4984 örneğin 3982’si doğru sınıflanmıştır. “Düşük Uygunluk” sınıfında da 3796 örnekten 3046’sı doğru tahmin edilmiştir. Sınıflar arasında kısmi çapraz tahminler olmasına rağmen bu oranlar oldukça düşüktür. Bu sonuçlar, modelin genel eğiliminin yüksek doğrulukla çalıştığını ve sınıflar arasında ayırma becerisinin güçlü olduğunu göstermektedir.

Tablo 4.8. FoodNet-C model metrikleri

Doğruluk	Hassasiyet	Duyarlılık	F1 Skoru
%84.11	%84	%84	%84



Şekil 4.13. FoodNet-C model karmaşıklık matrisi

Modelin performansı, geleneksel makine öğrenmesi algoritmaları ile karşılaştırmalı olarak değerlendirilmiştir. Bu kapsamda, Lojistik Regresyon modeli %79.74 doğruluk, K-En Yakın Komşu (KNN) modeli %82.40 doğruluk oranı sağlamıştır.

Geliştirilen FoodNet-C modeli, bu modellerin üzerinde bir başarı göstererek, çevresel ve iklimsel verilerin birlikte işlendiği bu görevde daha isabetli sonuçlar üretmiştir. Bu durum, derin öğrenme tabanlı modellerin karmaşık yapısal ilişkileri daha etkili bir şekilde öğrenebildiğini ortaya koymaktadır. Üretilen modelin makine öğrenmesi yöntemleri ile karşılaştırılması Tablo 4.9’da verilmiştir.

Tablo 4.9. FoodNet-C modelinin makine öğrenmesi yöntemleriyle karşılaştırması

Yöntem	Veri Kaynağı	Kullanım Alanı	Doğruluk
Lojistik Regresyon	Kolombiya kakao verisi	Gıda güvenliği	%79.74
K-En Yakın Komşu	Kolombiya kakao verisi	Gıda güvenliği	%82.40
FoodNet-C	Kolombiya kakao verisi	Gıda güvenliği	%84.11


4.3.4. Gıda Güvenliği Sonuçların Yorumlanması

Geliştirilen FoodNet-C modeli, kakao üretim alanlarının uygunluk düzeyini belirlemede başarılı sonuçlar vermiş ve test verileri üzerinde %84.11 doğruluk oranı elde etmiştir. Modelin bu başarısı, çevresel ve iklimsel faktörlerin birlikte değerlendirilmesiyle güçlendirilmiştir. Ayrıca modelin geleneksel sınıflandırma yöntemleriyle yapılan karşılaştırmalarda daha yüksek doğruluk sağlaması, derin öğrenme temelli yaklaşımların tarımsal analizlerdeki üstünlüğünü ortaya koymaktadır.

Eğitim ve test süreçlerinden elde edilen tahminler, mekânsal düzeyde değerlendirilebilmek için interaktif bir harita üzerinde görselleştirilmiştir. Harita üzerinde her bir tarım arazisi, modelin öngördüğü uygunluk sınıfına göre renklendirilmiştir; yüksek uygunluk **kırmızı**, orta uygunluk **turuncu**, düşük uygunluk için **yeşil** rengi kullanılmıştır.

Bu görselleştirme sayesinde, Kolombiya'daki kakao üretimi için en verimli alanların coğrafi olarak belirlenmesi sağlanmıştır. Görsel çıktı, karar vericiler ve planlamacılar için önemli bir referans niteliği taşımakta; gıda güvenliği açısından risk taşıyan bölgelerin önceden tespit edilmesine olanak sunmaktadır.

Aşağıdaki Şekil 4.14'de örnek harita görselinde, modelin sınıflandırdığı kakao uygunluk alanları mekânsal olarak sunulmaktadır. Bu yaklaşım, tarımda veri destekli karar mekanizmalarının güçlendirilmesi açısından etkili bir araçtır.



Şekil 4.14. FoodNet-C örnek çıktısı

4.4. Genel Değerlendirme

Bu bölümde, kuraklık riski, su güvenliği ve gıda güvenliği konularına yönelik olarak üç farklı derin öğrenme tabanlı sınıflandırma modeli geliştirilmiştir. Her bir model, kendi veri setine ve çevresel parametrelerine özgü şekilde yapılandırılmış, doğruluk oranları ve mekânsal analiz çıktılarıyla değerlendirilmiştir. Kullanılan veri setlerinin büyüklüğü ve öznitelik sayısı Tablo 4.10’da verilmiştir. Tablo 4.11 ise geliştirilen modellerin, literatür ile karşılaştırması özetlenmektedir.

Tablo 4.10. Kuraklık riski, gıda güvenliği ve su güvenliği veri setlerinin büyüklük ve öznitelik sayıları

Veri Seti	Toplam Kayıt Sayısı	Öznitelik sayısı
Kuraklık Riski Veri Seti	2980	26
Su Güvenliği Veri Seti	500	22
Gıda Güvenliği Veri Seti	57658	106

Tablo 4.11. Kuraklık riski, gıda güvenliği ve su güvenliği modellerinin literatür ile karşılaştırması

Yöntem	Veri Kaynağı	Kullanım Alanı	Doğruluk
DroughtNet-X	ABD tarım verisi	Kuraklık riski	%81.21
Raza ve ark. [55]	Uydu görüntüleri	Kuraklık sınıflandırması	En yüksek DenseNet ve RestNet modelleri ile %70
WS-RiskNet	Tarımsal iklim verileri	Su güvenliği riski	%92
Chatterjee ve ark. [56]	Su Kalitesi ve içilebilirlik göstergeleri	Su güvenliği	Makine öğrenmesi modelleri ile %58-69
FoodNet-C	Kolombiya kakao verisi	Gıda güvenliği	%84.11
Khikmah ve ark. [57]	Anket tabanlı	Gıda güvenliği	%65.795

Bu çalışma kapsamında geliştirilen DroughtNet-X, WS-RiskNet ve FoodNet-C modelleri, literatürdeki benzer uygulamalarla karşılaştırıldığında doğruluk açısından dikkat çekici bir üstünlük sergilemektedir. DroughtNet-X modeli, arazi kullanımı, toprak nemi ve çevresel iklim parametrelerini bütüncül bir şekilde değerlendirerek kuraklık riski sınıflandırmasında %81.21 oranında doğruluğa ulaşmıştır. Oysa Raza ve ark. tarafından yalnızca uydu görüntüleriyle gerçekleştirilen kuraklık evresi sınıflandırmasında, en yüksek başarı DenseNet ve ResNet modelleriyle dahi %70 seviyesinde kalmıştır. Bu fark, veri çeşitliliği ve derin öğrenmenin karmaşık ilişkileri modelleme yeteneği ile açıklanabilir. Benzer şekilde, WS-RiskNet modeli, tarımsal iklimsel verilerin analiziyle su güvenliği tahmininde %92 doğruluk elde etmiş; bu oran, Chatterjee ve ark. geleneksel makine öğrenmesi algoritmalarıyla ulaştığı %58–69 aralığındaki doğruluk oranlarının oldukça üzerindedir. FoodNet-C modeli ise, Kolombiya'daki kakao üretim alanlarını baz alan veri seti ile çalışarak gıda güvenliği değerlendirmesinde %84.11 doğruluk sağlamış, oysa Khikmah ve ark. anket tabanlı sınıflandırma çalışması %65.795 gibi daha sınırlı bir başarı sunmuştur.

Elde edilen bulgular, klasik yöntemlerin belirli veri türleriyle sınırlı kaldığını ve çevresel karmaşıklıkları yeterince temsil edemediğini ortaya koymaktadır. Öte yandan, önerilen derin öğrenme tabanlı modeller, çok boyutlu tarımsal verilerin analizinde daha başarılı sonuçlar vermiş ve bu başarıyı, mekânsal düzeyde haritalandırılmış risk tahminleriyle desteklenmiştir. Haritalar aracılığıyla ortaya konan görsel analizler, tarımsal yönetim politikalarının bölgesel düzeyde optimize edilmesine olanak sağlayarak karar vericilere somut destek sunmaktadır.

5. SONUÇLAR, TARTIŞMA VE ÖNERİLER

Bu tez çalışması, artan kuraklık tehdidi, azalan su kaynakları ve sürdürülebilir tarım ihtiyacının bir sonucu olarak, tarımsal karar destek sistemlerinin uydu ve meteorolojik verilerle desteklenerek güçlendirilmesini hedeflemiştir. Bu doğrultuda geliştirilen önerilen yöntem, akıllı tarım verisi analizi kapsamında hem bilimsel derinlik hem de uygulamaya dönük erişilebilirlik sağlayan çift akışlı bir mimariye dayanmaktadır:

Birinci akış, Sentinel-2 uydu verileri kullanılarak bitki sağlığı ve toprak nemi tahmininde bulunmayı amaçlamaktadır. Bu kapsamda, NDVI ve NDMI gibi spektral indekslerin çıkarılması ve RandomForestRegressor algoritması ile tahmin modelinin eğitilmesi sağlanmıştır. 500 örnekle sınırlı bir veri seti kullanılmasına rağmen, %86–88 doğruluk oranı ile literatürdeki birçok çalışmadan daha üstün sonuçlar elde edilmiştir. Elde edilen bu başarı, yöntemin bölge bazlı ve amaca yönelik optimize edilmesiyle yakından ilişkilidir. Ayrıca, çalışmada yöntemin büyük hacimli, genellenmiş veri kümeleriyle değil, kullanıcıdan alınan konum bilgisine dayalı olarak hedeflenmiş şekilde çalışması, saha koşullarına ve yerel tarım ihtiyaçlarına daha doğrudan çözüm üretmesini sağlamıştır.

İkinci akış ise OpenEO üzerinden sağlanan meteorolojik veriler aracılığıyla tarım üreticilerinin hava koşullarına bağlı olarak yönlendirilmesini amaçlamaktadır. Bu akışta herhangi bir makine öğrenimi modeli yerine, kullanıcının belirli bir gün aralığı için seçtiği bölgeye ait veriler alınmakta; sıcaklık, yağış, nem gibi parametreler basit bir algoritma yardımıyla analiz edilerek, sulama, ekim zamanı veya hastalık riski gibi konularda yorumlama yapılmaktadır. Bu yapının özelleştirilebilir ve zamanla geliştirilebilir olması sayesinde, çiftçilere dinamik karar desteği sunulabilmektedir.

Bu temel mimariye ek olarak, çalışmanın 4. bölümünde geliştirilen derin öğrenme modelleri aracılığıyla kuraklık riski, su güvenliği ve gıda güvenliği ayrı ayrı analiz edilmiştir.

Bu kapsamda:

- **Kuraklık riski tahmini** için geliştirilen DroughtNet-X adlı model, ABD tarım alanlarına ait çevresel verilerle eğitilmiş ve %81.21 doğruluk oranı ile başarılı bir performans göstermiştir. Model çıktıları haritalandırılarak, mekânsal risk dağılımı açık şekilde görselleştirilmiştir.
- **Su güvenliği riski** için tasarlanan WS-RiskNet modeli, çeşitli meteorolojik ve toprak nemi verilerini kullanarak %92 doğruluk oranına ulaşmış; bu yönüyle klasik makine öğrenmesi yöntemlerinin üzerinde bir başarı elde etmiştir. Ayrıca modelin mekânsal genelleme kabiliyeti harita üzerinde net bir şekilde gözlemlenmiştir.
- **Gıda güvenliği tahmini** amacıyla geliştirilen FoodNet-C modeli, Kolombiya'daki kakao üretim alanları üzerinden test edilmiş ve %84.11 doğruluk ile hem istatistiksel hem de

coğrafi olarak tutarlı sonuçlar üretmiştir. Harita üzerinde yüksek uygunluk bölgeleri kırmızı, orta uygunluk turuncu, düşük uygunluk ise yeşil renkle temsil edilerek kullanıcı dostu bir çıktı sunulmuştur.

Geliştirilen sistem yalnızca akademik bir başarı değil, aynı zamanda gerçek dünya koşullarına uygulanabilirliği yüksek, kullanıcıya yönelik sade ve etkileşimli bir çözüm sunmaktadır. Tezde geliştirilen yazılım arayüzü sayesinde, kullanıcıların kendi koordinatlarını sisteme girmesiyle veri analizi başlatılabilmekte, sonuçlar sözel olarak sunulmakta ve elde edilen bulgular anlaşılabilir şekilde raporlanmaktadır. Bu durum, hem bilimsel analiz hem de kullanıcı deneyimi açısından önemli bir kazanım sağlamaktadır.

Ayrıca, sistemin açık kaynak veri kaynaklarına dayanması (Sentinel-2 ve OpenEO), yüksek maliyetli ekipmanlara ihtiyaç duyulmaksızın hem araştırma amaçlı hem de sahada kullanılabilirliği mümkün kılmaktadır. Böylelikle yalnızca araştırmacılar değil, tarım ile uğraşan üreticiler, tarım danışmanları ve politika yapımcılar da sistemin çıktılarından yararlanabilecektir.

Bu tez kapsamında gerçekleştirilen araştırma sonucunda bilim dünyasına ve uygulama alanına yönelik aşağıdaki özgün katkılar sağlanmıştır:

- **Uydu ve Meteorolojik Verilerin Entegrasyonu ile Çift Akışlı Bir Karar Destek Sistemi Geliştirilmiştir:** Geliştirilen sistem, Sentinel-2 uydu verileri ve OpenEO meteorolojik verileri birlikte kullanılarak kuraklık, su güvenliği ve gıda güvenliği gibi kritik konularda çok yönlü analiz imkânı sunmuştur.
- **Derin Öğrenme Modelleri ile Yüksek Doğruluk Oranları Elde Edilmiştir:** Kuraklık riski için geliştirilen DroughtNet-X modeli %81.21; su güvenliği için WS-RiskNet modeli %92; gıda güvenliği için FoodNet-C modeli ise %84.11 doğrulukla çalışarak literatürdeki klasik makine öğrenmesi yöntemlerine kıyasla anlamlı üstünlük göstermiştir.
- **Coğrafi Duyarlılığı Yüksek Risk Haritaları Üretilmiştir:** Modellerin çıktıları mekânsal düzeyde haritalandırılarak, tarımsal risklerin bölgesel dağılımı kullanıcı dostu görsellerle sunulmuş ve bölge planlamaları için karar destek aracı işlevi kazanmıştır.
- **Açık Kaynak Tabanlı, Uygulanabilir ve Erişilebilir Bir Sistem Ortaya Konmuştur:** Geliştirilen sistem, yüksek maliyetli ekipmanlara gerek duyulmadan, açık veri kaynakları kullanılarak hem akademik araştırmalar hem de sahadaki kullanıcılar tarafından kullanılabilir hale getirilmiştir.
- **Yerel Koşullara Duyarlı, Kullanıcı Girdisine Dayalı Dinamik Yapı Geliştirilmiştir:** Sistem, sabit veri kümeleri yerine kullanıcı tarafından belirlenen koordinatlara göre analiz gerçekleştirebilme yeteneğine sahiptir. Bu yapı sayesinde yerel ve bireysel karar verme süreçlerine katkı sağlanmıştır.
- **Tarımsal Dijital Dönüşüm Sürecine Katkı Sağlayan Etkileşimli Bir Yazılım Arayüzü Sunulmuştur:** Kullanıcılar kendi koordinatlarını girerek sistemden analiz çıktıları elde

edebilmekte, bu da dijital tarım okuryazarlığını destekleyici bir kazanım olarak öne çıkmaktadır.

- **Sürdürülebilir Tarım Politikaları İçin Bilimsel Altyapı Sağlanmıştır:** Elde edilen bulgular, uzun vadeli tarım stratejilerinin, ürün destekleme politikalarının ve iklim uyumlu tarım uygulamalarının şekillendirilmesinde referans niteliğindedir.

Tüm bu yapı değerlendirildiğinde, önerilen yöntemin sadece kısa vadeli analizler için değil, aynı zamanda uzun vadeli tarım stratejilerinin planlanması, gıda ve su güvenliği ile ilgili politikaların desteklenmesi ve sürdürülebilir tarım uygulamalarının yaygınlaştırılması açısından da önemli bir katkı sunduğu görülmektedir. Modelin gelecekte daha fazla veri ile genişletilmesi, farklı bölgelerde test edilmesi ve kullanıcı geribildirimleri ile desteklenmesi, sistemin etki alanını daha da genişletecektir.

Tarımsal üretimin giderek daha büyük iklimsel belirsizliklerle karşı karşıya kaldığı günümüzde, geliştirilen sistem gibi veri odaklı karar destek araçlarının önemi daha da artmaktadır.

Gelecekte bu sistemin geliştirilebileceği başlıca yönler şunlardır:

- **Veri Tabanının Genişletilmesi:** Farklı bölgelerden toplanacak daha fazla örnekleme ile modelin genellenebilirliği artırılabilir. Örneğin farklı ürün türlerine, iklim bölgelerine ve toprak yapılarına göre ayrı modeller oluşturulabilir.
- **Mobil ve Gerçek Zamanlı Uygulama Geliştirmeleri:** Sistemin bir mobil uygulamaya dönüştürülmesi, sahadaki üreticilerin anlık analiz talebinde bulunmasını ve uyarı sistemlerinden faydalanmasını mümkün kılacaktır.
- **Uydu Görüntülerine Dayalı Derin Öğrenme Modelleri:** Görüntü tabanlı derin öğrenme modelleri (örneğin U-Net, CNN, Transformer tabanlı modeller) ile doğrudan piksel düzeyinde tahminler yapılabilir. Bu durum hem mekânsal hem de zamansal doğruluğu artıracaktır.
- **Yapay Zekâ Destekli Uyarı Sistemleri:** Mevsimsel desenleri tanıyan ve geçmiş verilerle geleceği tahmin eden AI tabanlı alarm sistemleri, erken müdahale imkânı sunabilir. Örneğin: “önümüzdeki 10 gün içinde yağış olmayacağı için sulama yapılmalıdır” gibi yönlendirmeler otomatik üretilebilir.
- **Politika ve Strateji Geliştirme Desteği:** Bölgesel tarım planlaması, ürün destekleme politikaları ve kuraklıkla mücadele stratejilerinde bu tür sistemlerden elde edilen verilerden faydalanmak mümkündür.

Sonuç olarak, bu tezde önerilen yöntem; akademik literatür ile uyumlu, doğruluk açısından rekabetçi, uygulanabilirlik açısından sahaya indirgenmiş ve toplumsal fayda açısından etkili bir çözüm sunmaktadır. Geliştirilen sistem, yalnızca teknolojik bir başarı değil; aynı zamanda bilgiye dayalı tarım kararlarının alınmasına katkı sunarak, bilinçli üretici profilinin gelişmesine ve tarımda dijital dönüşümün yaygınlaşmasına zemin hazırlamaktadır.

KAYNAKLAR

- [1] A. Saleem; S. Anwar; T. Nawaz; S. Fahad; S. Saud; T. U. Rahman; M. N. R. Khan, “Securing a sustainable future: the climate change threat to agriculture, food security, and sustainable development goals,” *J. Umm Al Qura Univ. Appl. Sci.*, pp. 1–17, 2024.
- [2] S. Chinchorkar, “Utilizing satellite data and machine learning to monitor agricultural vulnerabilities to climate change,” *Int. J. Geography, Geology and Environment*, 2025.
- [3] R. Thamizhamuthu; M. Revathi; V. Jaiswal; P. Kohli, “An Analysis of Satellite Imagery for Crop Production using Deep Learning Techniques,” in *Proc. Int. Conf. Sustainability Innovation in Computing and Engineering (ICSICE)*, Atlantis Press, pp. 125–137, 2025.
- [4] J. L. Jewiss; M. E. Brown; V. M. Escobar, “Satellite remote sensing data for decision support in emerging agricultural economies: How satellite data can transform agricultural decision making,” *IEEE Geosci. Remote Sens. Mag.*, vol. 8, no. 4, pp. 117–133, 2020.
- [5] R. Dainelli; F. Saracco, “Bibliometric and social network analysis on the use of satellite imagery in agriculture: an entropy based approach,” *Agronomy*, vol. 13, no. 2, p. 576, 2023.
- [6] T. T. Nguyen; H. T. Dat; M. T. Pham; V. T. Trinh; N. T. Hung; Q. T. Huynh; J. Jo, “Monitoring agriculture areas with satellite images and deep learning,” *Appl. Soft Comput.*, vol. 95, p. 106565, 2020.
- [7] A. A. Belal; A. Fadl; A. Elhaddad; N. Al Ansari; R. Najaar; S. Shahid; A. Omran; M. Elshamy; M. Elzraki; M. Temsah; M. Elsebai, “Drought risk assessment using remote sensing and GIS techniques,” *Arabian J. Geosci.*, vol. 7, pp. 35–53, 2014.
- [8] C. Canedo Rosso; M. Figueroa Ruiz; R. Arias Tama; B. Condori; L. Gonzales; M. Mamani; P. Rojas; E. Yucra, “Drought impact in the Bolivian Altiplano agriculture associated with the El Niño–Southern Oscillation using satellite imagery data,” *Nat. Hazards Earth Syst. Sci.*, vol. 21, no. 3, pp. 995–1010, 2021.
- [9] A. Moreno; R. García Herrera; I. Sánchez Rodríguez; J. Martínez Fernández, “Monitoring water stress in Mediterranean semi natural vegetation with satellite and meteorological data,” *Int. J. Appl. Earth Obs. Geoinf.*, vol. 26, pp. 246–255, 2014.
- [10] C. Kulatunga; S. Dhelim; T. Kechadi, “Machine learning for dynamic management zone in smart farming,” *arXiv preprint arXiv:2408.00789*, 2024.
- [11] H. Zhu; C. Lin; G. Liu; D. Wang; S. Qin; A. Li; J. L. Xu; Y. He, “Intelligent agriculture: Deep learning in UAV based remote sensing imagery for crop diseases and pests detection,” *Front. Plant Sci.*, vol. 15, p. 1435016, 2024.
- [12] S. Ghazal; A. Munir; W. S. Qureshi, “Computer vision in smart agriculture and precision farming: Techniques and applications,” *Artif. Intell. Agric.*, vol. 13, pp. 64–83, Sep. 2024.
- [13] M. Rezwaniul Mahmood; Mohammad Abdul Matin; Sotirios K. Goudos; George K. Karagiannidis, “Machine learning for smart agriculture: a comprehensive survey,” *IEEE Trans. Artif. Intell.*, vol. 5, no. 6, pp. 2568–2588, 2023.
- [14] Sowmya, B. J., Meeradevi, A. K., Supreeth, S., Pradeep Kumar, D., Ravi Kumar, B. N., Rohith, S., ... & Patil, A. U. (2025). Leveraging machine learning for intelligent agriculture. *Discover Internet of Things*, 5(1), 33.
- [15] Botero-Valencia, J., García-Pineda, V., Valencia-Arias, A., Valencia, J., Reyes-Vera, E., Mejia-Herrera, M., & Hernández-García, R. (2025). Machine learning in sustainable agriculture: systematic review and research perspectives. *Agriculture*, 15(4), 377.
- [16] Qin, Y. M., Tu, Y. H., Li, T., Ni, Y., Wang, R. F., & Wang, H. (2025). Deep Learning for sustainable agriculture: A systematic review on applications in lettuce cultivation. *Sustainability*, 17(7), 3190.
- [17] Miller, T., Mikiciuk, G., Durlik, I., Mikiciuk, M., Łobodzińska, A., & Śnieg, M. (2025). The IoT and AI in Agriculture: The Time Is Now—A Systematic Review of Smart Sensing Technologies. *Sensors (Basel, Switzerland)*, 25(12), 3583.

- [18] Yao, J., Tran, S. N., Sawyer, S., & Garg, S. (2023). Machine learning for leaf disease classification: data, techniques and applications. *Artificial Intelligence Review*, 56(Suppl 3), 3571-3616.
- [19] Kallenberg, M. G., Maestrini, B., van Bree, R., Ravensbergen, P., Pylianidis, C., van Evert, F., & Athanasiadis, I. N. (2023). Integrating processed-based models and machine learning for crop yield prediction. *arXiv preprint arXiv:2307.13466*.
- [20] Afzal, H., Amjad, M., Raza, A., Munir, K., Villar, S. G., Lopez, L. A. D., & Ashraf, I. (2025). Incorporating soil information with machine learning for crop recommendation to improve agricultural output. *Scientific Reports*, 15(1), 8560.
- [21] Poblete, T., Navas-Cortes, J. A., Hornero, A., Camino, C., Calderon, R., Hernández-Clemente, R., ... & Zarco-Tejada, P. J. (2023). Detection of symptoms induced by vascular plant pathogens in tree crops using high-resolution satellite data: Modelling and assessment with airborne hyperspectral imagery. *Remote Sensing of Environment*, 295, 113698.
- [22] Tunçay, T., Kılıç, Ş., Dedeoğlu, M., Dengiz, O., Başkan, O., & Bayramin, I. (2021). Assessing soil fertility index based on remote sensing and gis techniques with field validation in a semiarid agricultural ecosystem. *Journal of Arid Environments*, 190, 104525.
- [23] Chawla, I., Karthikeyan, L., & Mishra, A. K. (2020). A review of remote sensing applications for water security: Quantity, quality, and extremes. *Journal of Hydrology*, 585, 124826.
- [24] Santos, C., Lorite, I. J., Tasumi, M., Allen, R. G., & Fereres, E. (2010). Performance assessment of an irrigation scheme using indicators determined with remote sensing techniques. *Irrigation Science*, 28(6), 461-477.
- [25] M. Ghobadi and Z. Badehian, "Assessment of agricultural drought severity using multi-temporal remote sensing data in Lorestan region," *Sci. Rep.*, vol. 15, no. 1, pp. 1–13, 2025.
- [26] T. Satapathy, J. Dietrich, and M. Ramadas, "Agricultural drought monitoring and early warning at the regional scale using a remote sensing-based combined index," *Environ. Monit. Assess.*, vol. 196, no. 11, p. 1132, 2024.
- [27] Christian, J. I., Hobbins, M., Hoell, A., Otkin, J. A., Ford, T. W., Cravens, A. E., ... & Mishra, V. (2024). Flash drought: A state of the science review, *WIREs Water*, 11, e1714.
- [28] Lin, F., Crawford, S., Guillot, K., Zhang, Y., Chen, Y., Yuan, X., ... & Tzeng, N. F. (2023). Mmst-vit: Climate change-aware crop yield prediction via multi-modal spatial-temporal vision transformer. In *Proceedings of the IEEE/CVF International Conference on Computer Vision* (pp. 5774-5784).
- [29] Liu, S., Wang, D., Guo, H., Han, C., & Zeng, W. (2025). MT-CYP-Net: Multi-Task Network for Pixel-Level Crop Yield Prediction Under Very Few Samples. *arXiv preprint arXiv:2505.12069*.
- [30] Chen, H., Yang, N., Song, X., Lu, C., Lu, M., Chen, T., & Deng, S. (2025). A novel agricultural drought index based on multi-source remote sensing data and interpretable machine learning. *Agricultural Water Management*, 308, 109303.
- [31] Zha, X., Jia, S., Han, Y., Zhu, W., & Lv, A. (2025). Enhancing Soil Moisture Prediction in Drought-Prone Agricultural Regions Using Remote Sensing and Machine Learning Approaches. *Remote Sensing*, 17(2), 181.
- [32] Siasar, H., Salari, A., Bahrami, M., & Hamidifar, H. (2025). Integrating remote sensing and meteorological analysis for monitoring drought conditions in arid regions: a case study from Sistan and Baluchestan province, Iran. *Theoretical and Applied Climatology*, 156(5), 291.
- [33] M. F. Çakmakçı and R. Çakmakçı, "Uzaktan algılama, yapay zekâ ve geleceğin akıllı tarım teknolojisi trendleri," *Avr. Bilim Teknol. Derg.*, no. 52, pp. 234–246, 2023.
- [34] Judith, J., Tamilselvi, R., Beham, M. P., Lakshmi, S., Panthakkan, A., Mansoori, S. A., & Ahmad, H. A. (2025). Remote Sensing Based Crop Health Classification Using NDVI and Fully Connected Neural Networks. *arXiv preprint arXiv:2504.10522*.

- [35] Aldhahri, E. A., Almazroi, A. A., Alkinani, M. H., Ayub, N., Alghamdi, E. A., & Janbi, N. F. (2025). Smart Farming: Enhancing Urban Agriculture through Predictive Analytics and Resource Optimization. IEEE Access.
- [36] Jewiss, Jennifer L., Molly E. Brown, and Vanessa M. Escobar. "Satellite remote Sensing data for decision Support in emerging Agricultural economies: How Satellite data can transform Agricultural decision making [Perspectives]." IEEE Geoscience and Remote Sensing Magazine 8.4 (2020): 117-133.
- [37] J. C. Cacal, E. B. Taboada, and M. S. Mehboob, "Strategic Implementation of Integrated Water Resource Management in Selected Areas of Palawan: SWOT-AHP Method," Sustainability, vol. 15, no. 4, p. 2922, 2023.
- [38] G. S. Mmbando, "Harnessing artificial intelligence and remote sensing in climate-smart agriculture: the current strategies needed for enhancing global food security," Cogent Food Agric., vol. 11, no. 1, p. 2454354, 2025.
- [39] Parra-López, C., Abdallah, S. B., Garcia-Garcia, G., Hassoun, A., Trollman, H., Jagtap, S., ... & Carmona-Torres, C. (2025). Digital technologies for water use and management in agriculture: Recent applications and future outlook. Agricultural Water Management, 309, 109347.
- [40] Johri, P., Sharma, K. P., Chauhan, A., & Sunilkhatri. (2023). Role of satellites in agriculture. Evolving Networking Technologies: Developments and Future Directions, 165-175.
- [41] Aqdam, K. K., Rezapour, S., Asadzadeh, F., & Nouri, A. (2023). An integrated approach for estimating soil health: Incorporating digital elevation models and remote sensing of vegetation. Computers and Electronics in Agriculture, 210, 107922.
- [42] A. Jędrzejek, J. Jadczyzyn, and R. Pudelko, "Increasing Accuracy of the Soil-Agricultural Map by Sentinel-2 Images Analysis—Case Study of Maize Cultivation under Drought Conditions," Remote Sens., vol. 15, no. 5, p. 1281, 2023.
- [43] Alkhalidi, A., Assaf, M. N., Alkaylani, H., Halaweh, G., & Salcedo, F. P. (2023). Integrated innovative technique to assess and priorities risks associated with drought: Impacts, measures/strategies, and actions, global study. International Journal of Disaster Risk Reduction, 94, 103800.
- [44] Java, <https://www.java.com/tr/> (Erişim tarihi: 05.06.2025).
- [45] JetBrains IntelliJ IDEA, <https://www.jetbrains.com/idea/> (Erişim tarihi: 05.06.2025).
- [46] Spring Framework, <https://spring.io/> (Erişim tarihi: 05.06.2025).
- [47] Thymeleaf – Java Template Engine, <https://www.thymeleaf.org/> (Erişim tarihi: 05.06.2025).
- [48] Sentinel Hub – Satellite Data for Developers, <https://www.sentinel-hub.com/> (Erişim tarihi: 05.06.2025).
- [49] OpenEO – Open Earth Observation Platform, <https://openeo.org/> (Erişim tarihi: 05.06.2025).
- [50] Shokati, H., Mashal, M., Noroozi, A., Abkar, A. A., Mirzaei, S., Mohammadi-Doqozloo, Z., ... & Scholten, T. (2024). Random forest-based soil moisture estimation using Sentinel-2, Landsat-8/9, and UAV-based hyperspectral data. Remote Sensing, 16(11), 1962.
- [51] Hassan-Esfahani, L., Torres-Rua, A., Jensen, A., & McKee, M. (2015). Assessment of surface soil moisture using high-resolution multi-spectral imagery and artificial neural networks. Remote Sensing, 7(3), 2627-2646.
- [52] Google Colaboratory, <https://colab.google/> (Erişim tarihi: 05.06.2025).
- [53] Python Software Foundation, <https://www.python.org/> (Erişim tarihi: 05.06.2025).
- [54] Kaggle – Veri Bilimi ve Makine Öğrenimi Platformu, <https://www.kaggle.com/> (Erişim tarihi: 05.06.2025).
- [55] M. O. Raza, A. S. Siddiqui, M. A. Siddiqui, ve M. I. Khan, "Evaluation of Deep Learning Approaches for Classification of Drought Stages Using Satellite Imagery for Tharparker," Sir Syed Univ. Res. J. Eng. Technol. (SSURJET), vol. 12, no. 2, 2022.

- [56] D. Chatterjee, S. Basu, R. Roy, ve A. Chakraborty, “Optimizing Machine Learning for Water Safety: A Comparative Analysis with Dimensionality Reduction and Classifier Performance in Potability Prediction,” *PLoS Water*, vol. 3, no. 8, e0000259, 2024.
- [57] K. N. Khikmah, S. R. Hidayat, R. Ramdhani, ve M. R. Abdullah, “Performance Comparative Study of Machine Learning Classification Algorithms for Food Insecurity Experience by Households in West Java,” *J. Online Inform.*, vol. 9, no. 1, pp. 128–137, 2024.



ÖZGEÇMİŞ

Serhat ATAŞ

KİŞİSEL BİLGİLER

ARAŞTIRMACI BİLGİLERİ

Öğrenci Orcid ID : 0000-0003-4995-1328
Danışman Orcid ID : 0000-0002-3276-3788

EĞİTİM BİLGİLERİ

L	

ARAŞTIRMA DENEYİMİ

✓ Java, Uydu verileri, RandomForestRegressor, Thymeleaf

İŞ DENEYİMİ

AKADEMİK FAALİYETLER

Makaleler:

- Atas, S., & Karakose, M. (2025). Integrating Satellite Imagery and Weather Data for Proactive Crop Health Management, Yayına hazırlanıyor, 2025.
- Karaköse, M., İlhan, İ., Yetiş, H., & Ataş, S. (2024). A New Approach for Deepfake Detection with the Choquet Fuzzy Integral. *Applied Sciences*, 14(16), 7216.
- Atas, S., & Karakose, M. (2023, October). A New Approach to in Ensemble Method for Deepfake Detection. In *2023 4th International Conference on Data Analytics for Business and Industry (ICDABI)* (pp. 201-204). IEEE.
- Ataş, S., & Karaköse, M. (2023, June). A New Classification Approach of Cultural Heritage: Deep Learning Based Image Recognition. In *2023 International Conference on Sustaining Heritage: Innovative and Digital Approaches (ICSH)* (pp. 95-99). IEEE.
- Ataş, S., İlhan, İ., & Karaköse, M. (2022, February). An efficient deepfake video detection approach with combination of efficientnet and xception models using deep learning. In *2022 26th International Conference on Information Technology (IT)* (pp. 1-4). IEEE.