T.C.
ISPARTA UYGULAMALI BİLİMLER ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ
MEKATRONİK MÜHENDİSLİĞİ ANABİLİM DALI

TOPRAKTAKİ BESİN DEĞERLERİNİN YAPAY ZEKA YÖNTEMLERİ İLE TAHMİN EDİLMESİ VE ANALİZİ: ISPARTA ÖRNEĞİ

Rabia İlknur ERKEN

Danışman
Dr. Öğr. Üyesi Gamze YAKUT

ISPARTA- 2025

© 2025 [Rabia İlknur ERKEN]

ETİK BEYANI

Isparta Uygulamalı Bilimler Üniversitesi Lisansüstü Eğitim Enstitüsü tez yazım kurallarına uygun olarak ve bilimsel ahlak ve geleneklere aykırı düşecek bir yol ve yardıma başvurmaksızın hazırladığım bu tez çalışmasında;

Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi, tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu, tez çalışmasında yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi, kullanılan verilerde ve ortaya çıkan sonuçlarda herhangi bir değişiklik yapmadığımı, bu tezde sunduğum çalışmanın özgün olduğunu, tezimle ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçlara katlanacağımı bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

30/05/2025

Rabia İlknur ERKEN

İÇİNDEKİLER

Sayfa

İÇİNDEKİLER i
ÖZET iii
ABSTRACT iv
TEŞEKKÜR v
ŞEKİLLER DİZİNİ vi
ÇİZELGELER DİZİNİ vii
SİMGELER VE KISALTMALAR DİZİNİ viii
1. GİRİŞ 1
1.1. Tarım Endüstrisi 1
1.2. Yapay Zekâ Teknolojisi 12
1.2.1. Yapay zekâ teknolojisinin tarihsel gelişimi 13
1.2.2. Yapay zekâ yöntemleri 15
1.2.2.1. Uzman sistemler 15
1.2.2.2. Yapay sinir ağları 16
1.2.2.3. Bulanık mantık 17
1.2.2.4. Genetik algoritma 18
1.2.2.5. Makine öğrenmesi 18
1.3. Tezin Amacı 22
2. LİTERATÜR 24
3. MATERYAL VE YÖNTEM 36
3.1. Materyal 36
3.1.1. NPK sensörü 36
3.1.1.1. NPK sensörlerinin uygulama alanları 37
3.1.1.2. NPK sensörlerinin avantajları 37
3.1.1.3. NPK sensörlerinin sınırlamaları 38
3.1.1.4. NPK sensörlerinin temel çalışma prensibi 39
3.1.1.5. NPK sensörlerinin toprak ölçüm parametreleri 40
3.1.1.6. NPK sensörlerinin özellikleri 40
3.1.1.7. Kablolama 41
3.1.2. Arduino UNO sensör 41
3.1.2.1. Güç 42
3.1.2.2. Arduino üzerindeki pinler 42
3.1.2.3. LED'ler 44
3.1.3. LCD ekran 44
3.1.3.1. LCD ekran kullanım alanları 45
3.1.4. RS485 dönüştürücü 45
3.1.4.1. RS485 dönüştürücü çalışma prensibi 46
3.1.4.2. RS485 dönüştürücü özellikleri 47
3.1.4.3. RS485 dönüştürücü kullanım alanları 48
3.1.5. Yapay zekâ sistemi 48
3.1.5.1. Yapay zekâ sistemi yöntemleri 49
3.1.5.2. Yapay zekâ sistemi uygulama alanları 51
3.1.6. Web sayfası 53
3.1.6.1. Frontend 53
3.1.6.2. Backend 54
3.1.6.3. API temelleri 54

3.2. Yöntem 56
3.2.1. NPK sistem 57
3.2.2. Python yazılım 59
3.2.3. Web tasarımı 63
4. BULGULAR 66
5. TARTIŞMA VE SONUÇ 78
KAYNAKÇA 80
ÖZGEÇMİŞ ..... **Hata! Yer işareti tanımlanmamış.**

ÖZET

Yüksek Lisans Tezi

TOPRAKTAKİ BESİN DEĞERLERİNİN YAPAY ZEKA YÖNTEMLERİ İLE TAHMİN EDİLMESİ VE ANALİZİ: ISPARTA ÖRNEĞİ

Rabia İlknur ERKEN

Isparta Uygulamalı Bilimler Üniversitesi
Lisansüstü Eğitim Enstitüsü
Mekatronik Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Gamze YAKUT

Dünya nüfusundaki hızlı artış, her dönemde önemli bir sorun teşkil etmiş; buna karşılık doğal kaynaklar sınırlı kalmıştır. Özellikle Sanayi Devrimi gibi dönemlerde artış hızı daha da yükselmiş, bu durum doğayı koruma sorumluluğunu daha da önemli hâle getirmiştir. Bilinçsiz gübreleme, aşırı zirai ilaç kullanımı ve gereksiz sulama gibi uygulamaların önüne geçilmesi, alınabilecek temel önlemler arasında yer almaktadır.

Bu çalışmada, çiftçilerin toprak analizine dayalı bilinçli tarım uygulamalarına yönlendirilmesi amaçlanmıştır. Bu kapsamda, Arduino tabanlı taşınabilir bir NPK (Azot, Fosfor, Potasyum) sensör cihazı geliştirilmiştir. Eğitim sürecinde, Isparta İl Özel İdaresi'nden temin edilen 5 803 adet gerçek toprak analiz verisi kullanılmıştır. Sensör cihazı ile topraktan elde edilen pH, fosfor ve potasyum verileri kullanılarak; satürasyon, kireç ve organik madde değerleri random forest, bagging, logistic regression, decision tree ve XGBoost algoritması ile tahmin edilmiştir. XGBoost algoritması sırasıyla satürasyon, kireç ve organik madde için 77.07, 98.89 ve 93.35 ile en yüksek doğruluk oranını vermiştir. Elde edilen tahminler, kullanıcı dostu bir web arayüzüyle çiftçilere sunulmuştur. Bu sistem sayesinde hem tarımsal verimliliğin artırılması hem de sürdürülebilir tarımın desteklenmesi hedeflenmiştir.

Anahtar Kelimeler: Makine öğrenmesi, XGBoost, Tarım verimliliği, Random forest, Bagging

2025, 88 sayfa

ABSTRACT

Master's Thesis

PREDICTION AND ANALYSIS OF NUTRIENT VALUES IN SOIL BY ARTIFICIAL INTELLIGENCE METHODS: AN EXAMPLE FROM ISPARTA

Rabia İlknur ERKEN

Isparta University of Applied Sciences
The Institute of Graduate Education
Department of Mechatronic Engineering

Supervisor: Asst. Prof. Dr. Gamze YAKUT

The rapid increase in the world population has always constituted a significant problem, while natural resources have remained limited. Especially during periods such as the Industrial Revolution, the rate of increase has become even higher, making the responsibility to protect nature even more crucial. Preventing practices such as unconscious fertilization, excessive use of agricultural chemicals, and unnecessary irrigation are among the fundamental measures that can be taken.

In this study, it was aimed to guide farmers towards conscious agricultural practices based on soil analysis. In this context, a portable Arduino-based NPK (Nitrogen, Phosphorus, Potassium) sensor device was developed. During the training phase, 5 803 real soil analysis data samples obtained from the Isparta Provincial Directorate of Special Administration were used. Using the pH, phosphorus, and potassium data collected from the soil via the sensor device, the values for saturation, lime, and organic matter were estimated with random forest, bagging, logistic regression, decision tree, and XGBoost algorithms. The XGBoost algorithm provided the highest accuracy rates for saturation, lime, and organic matter, with values of 77.07, 98.89, and 93.35, respectively. The obtained predictions were presented to farmers through a user-friendly web interface. Through this system, it is aimed to both increase agricultural productivity and support sustainable agriculture.

Key Words: Machine learning, XGBoost, Agricultural productivity, Random forest, Bagging

2025, 88 pages

TEŞEKKÜR

Akademik yolculuğum boyunca rehberliği ve desteğiyle bana yol gösteren danışman hocam Sayın Dr. Öğr. Üyesi Gamze YAKUT'a; katkılarını ve desteklerini her zaman yanımda hissettiren Sayın Prof. Dr. Türkün ŞAHİNBAŞKAN ve Sayın Doç. Dr. Savaş EVRAN'a içten teşekkürlerimi sunarım.

Araştırma ve uygulama çalışmalarımda fiziki imkânlar sağlayan Isparta İl Özel İdaresi'ne teşekkür ederim.

Varlığıyla her zaman yolumu aydınlatan sevgili annem Hüsna ÇAY'a, daima yanımda olan ve en güçlü destekçilerimden biri olan kardeşim Şerafettin Taha ÇAY'a ve bugün yanımda olmasa da bu başarıların hayalini birlikte kurduğumuz, her zaman kalbimde yaşattığım canım babam Mustafa ÇAY'a sonsuz teşekkür ederim.

Bu süreçte sabrı, anlayışı ve sevgisiyle beni motive eden; desteğini ve emeğini her zaman hissettiren sevgili eşim Yasin ERKEN'e en içten duygularımla teşekkür ederim.

Rabia İlknur ERKEN
ISPARTA, 2025

ŞEKİLLER DİZİNİ

Sayfa

Şekil 1.1. Bir uzman sistemin iç ve dış yapısı ……..……..……..……. 16
Şekil 1.2. Yapay sinir hücresi ağı ……..…….……..... 17
Şekil 1.3. Bir bulanık mantık sistemin yapısı ……..……... 17
Şekil 1.4. Genetik algoritma akış şeması ……..…….……..... 18
Şekil 1.5. Makine öğrenmesinin kategorileri ……....…….……..…..……... 22
Şekil 3.1. Makine öğrenimi şeması ……..…….……..... 50
Şekil 3.2. Toprak numuneleri ……..……..……..……... 58
Şekil 3.3. Toprak ölçüm görselleri ……..……... 58
Şekil 3.4. Kullanıcı arayüzü ……..……..……... 64
Şekil 3.5. Değer tahmin sonuçları ……..……..... 65
Şekil 4.1. Algoritmaların doğruluk oranları karşılaştırılması ……..……... 74
Şekil 4.2. Organik madde değerinin sınıflandırma performansı ……... 75
Şekil 4.3. Kireç değerinin sınıflandırma performansı ……... 76
Şekil 4.4. Satürasyon değerinin sınıflandırma performansı ……..... 76

ÇİZELGELER DİZİNİ

Sayfa

Çizelge 3.1. NPK sensör toprak ölçüm parametreleri 40
Çizelge 3.2. NPK sensör özellikleri 41
Çizelge 3.3. Kablolama özellikleri 41
Çizelge 3.4. LCD ekran özellikleri 45
Çizelge 3.5. Toprak numuneleri NPK ölçüm sonuçları 59
Çizelge 3.6. Toprak numuneleri il özel idare ölçüm sonuçları 59
Çizelge 3.7. Algoritmaların doğruluk oranları 62
Çizelge 4.1. Veri Seti ile Doğruluk Karşılaştırması 66
Çizelge 4.2. Temel başarı metrikleri 67
Çizelge 4.3. XGBoost sınıf performansı (satürasyon) 68
Çizelge 4.4. Random forest sınıf performansı (satürasyon) 68
Çizelge 4.5. Bagging sınıf performansı (satürasyon) 68
Çizelge 4.6. Decision tree sınıf performansı (satürasyon) 68
Çizelge 4.7. Logistic regression sınıf performansı (satürasyon) 68
Çizelge 4.8. XGBoost sınıf performansı (kireç) 70
Çizelge 4.9. Random forest sınıf performansı (kireç) 70
Çizelge 4.10. Bagging sınıf performansı (kireç) 70
Çizelge 4.11. Decision tree sınıf performansı (kireç) 70
Çizelge 4.12. Logistic regression sınıf performansı (kireç) 70
Çizelge 4.13. XGBoost sınıf performansı (organik madde) 72
Çizelge 4.14. Random forest sınıf performansı (organik madde) 72
Çizelge 4.15. Bagging sınıf performansı (organik madden) 72
Çizelge 4.16. Decision tree sınıf performansı (organik madde) 72
Çizelge 4.17. Logistic regression sınıf performansı (organik madde) 73

SİMGELER VE KISALTMALAR DİZİNİ

AdaBoost	Adaptive Boosting
AgriRec	Agriculture Recommender System
ANN	Artificial Neural Network
API	Application Programming Interface
AWS	Amazon Web Services
CatBoost	Categorical Boosting
CNN	Convolutional Neural Network
CORS	Cross-Origin Resource Sharing
CRS	Crisp Rule Set
CSS	Cascading Style Sheets
DNN	Deep Neural Network
DT	Decision Tree
ELI5	Explain Like I'm 5
EOIR	Electro-Optical Infrared
FRS	Fuzzy Rule Set
GNB	Gaussian Naive Bayes
GND	Ground
GPS	Global Positioning System
GPU	Graphics Processing Unit
GRNN	General Regression Neural Network
HTML	HyperText Markup Language
http	HyperText Transfer Protocol
IBM	International Business Machines Corporation
IoT	Internet of Things
JRip	Java RIPPER Implementation
JSON	JavaScript Object Notation
K	Potasyum
KRR	Kernel Ridge Regression
LCD	Liquid Crystal Display
LIME	Local Interpretable Model-Agnostic Explanations
LLM	Large Language Model
LR	Logistic Regression
MAE	Mean Absolute Error
MLP	Multilayer Perceptron
MSE	Mean Squared Error
N	Azot
NPK	Azot, Fosfor, Potasyum Sensörü
P	Fosfor
PART	Partial Decision Trees
PM10	Particulate Matter 10 microns
PWM	Pulse Width Modulation
R^2	Coefficient of Determination
RBF	Radial Basis Function
RF	Random Forest
RGB	Red Green Blue
RIPPER	Repeated Incremental Pruning to Produce Error Reduction
RMSE	Root Mean Square Error
RX	Receive (Alıcı)

SEO	Search Engine Optimization
SHAPS	SHAPSHapley Additive exPlanations
SMS	Short Message Service
SO_2	Sulfur Dioxide
SPI	Serial Peripheral Interface
SVM	Support Vector Machine
SVR	Support Vector Regression
TCRM	Total Customer Relationship Management
TFT	Thin Film Transistor
TX	Transmit (Verici)
UART	Universal Asynchronous Receiver/Transmitter
URL	Uniform Resource Locator
USB	Universal Serial Bus
XGBoost	Extreme Gradient Boosting
YSA	Yapay Sinir Ağı

1. GİRİŞ

1.1. Tarım Endüstrisi

Tarım; bitkisel ve hayvansal üretimin gerçekleştirilmesi, elde edilen ürünlerin uygun koşullarda muhafaza edilmesi, işlenerek ekonomik değere dönüştürülmesi ve pazarlanması süreçlerini kapsayan bir bilim alanıdır (Doğan vd., 2015; Bayrakçı vd., 2021). Toprak ise, canlı yaşamının sürdürülmesinde temel bir unsur olup, yeryüzünü kaplayan en önemli doğal varlıklardan biridir. Tarım sektörü, yalnızca ekonomik kalkınma açısından değil, aynı zamanda toplumsal refah ve halk sağlığı bakımından da stratejik bir öneme sahiptir. Bu nedenle toprağın korunması, gelecek nesillere bırakılabilecek en kıymetli miraslardan biri olarak değerlendirilmelidir (Turan, 2022).

Tarım sektörü, insanlık tarihi boyunca farklı evrelerden geçmiş olsa da her dönemde yaşamın sürdürülebilirliği açısından temel bir yapı olmayı sürdürmüştür. Zaman içerisinde uygulanan çeşitli üretim yöntemleriyle tarımsal verim artışı sağlanmış olsa da dünya nüfusundaki hızlı büyüme gıda ihtiyacını her geçen gün katlayarak arttırmaktadır (Doğan vd., 2015; Terzi vd., 2019; Güzel, 2022). Toplumların ve dolayısıyla ülkelerin kalkınmasında kritik rol üstlenen bu sektör; küreselleşme, iklimsel dalgalanmalar, artan rekabet, tarım arazilerinin daralması ve pazar koşullarındaki değişkenlikler gibi faktörler nedeniyle her geçen gün daha stratejik bir konuma gelmektedir (Doğan vd., 2015; Hayaloğlu, 2018; Kılavuz ve Erdem, 2019).

İlk çağlarda avcılık ve toplayıcılıkla başlayan tarım faaliyetleri, günümüzde ileri teknolojilerin kullanıldığı modern sistemlerle sürdürülmektedir (Bayar, 2018). Ancak, tarım sektörünün gelişim süreci tarihsel süreçte pek çok engelle karşı karşıya kalmıştır. Örneğin, toprak uzun yıllar nadasa bırakılmış, ürün deseninde çeşitlilik sağlanamamış, yalnızca hayvan gübresi kullanılmış, yer altı su kaynakları etkin bir şekilde kullanılmamış ve makineleşme beraberinde çeşitli sorunlar getirmiştir (Doğan vd., 2015; Kılavuz ve Erdem, 2019). Bu gibi tarım sektörünün karşılaşmış olduğu engeller, tarımsal kalkınma sürecini yavaşlatmış ve verimliliğin artmasını sınırlamıştır. Ayrıca, tarıma elverişli alanların sınırlı olması, üretim artışının mevcut araziler üzerinde verim artışı ile sağlanmasını zorunlu kılmıştır (Güzel, 2022).

Nüfus, belirli bir zaman diliminde ve coğrafi alanda yaşayan insan sayısını ifade eder. Avcı-toplayıcı topluluklardan günümüz modern toplumlarına kadar geçen süreçte sürekli bir artış gösteren nüfus, tarih boyunca zaman zaman bir sorun kaynağı olarak değerlendirilmiştir. Tarıma elverişli arazilerin sınırlı olması, artan dünya nüfusu karşısında daha verimli üretim yöntemlerine olan ihtiyacı artırmaktadır (Aksu, 2011; Bayar, 2018; İnan ve Karcı, 2021). Günümüzde ise hızlı nüfus artışı; artan tüketim eğilimleri, azalan tarım arazileri, tükenen su kaynakları ve sıklaşan doğal afetler gibi pek çok sorunu beraberinde getirmekte, bu da küresel ölçekte bir gıda krizini tetiklemektedir (Yılmaz vd., 2009; Çetiner, 2011; Ercan vd., 2019). İlk olarak Ziraat Devrimi ile belirgin bir ivme kazanan nüfus artışı, Sanayi İnkılabı ile birlikte tarihsel bir sıçrama yaşamıştır. Bu dönem literatürde "Demografik Dönem" olarak anılmakta; açlık, yoksulluk ve susuzluk gibi temel yaşam sorunlarının yoğunlaştığı bir evre olarak tanımlanmaktadır (Aksu, 2011; Bayar, 2018; İnan ve Karcı, 2021).

İnsanların yaşamlarını sürdürebilmek için ihtiyaç duydukları kalori miktarını karşılama güdüsü, toplulukların yerleşik yaşama geçmesindeki en güçlü etkenlerden biri olmuştur (Türkoğlu, 1958; Doğan vd., 2015). MÖ 10 000'li yıllarda yerleşik hayata geçiş, Neolitik Devrim olarak adlandırılmakta olup bu dönemde bitkilerin yetiştirilmesi ve hayvanların evcilleştirilmesi başlamıştır. Neolitik çağlardan günümüze kadar insanlar, besin ihtiyaçlarını tarımsal faaliyetler yoluyla karşılamış; zaman içerisinde daha verimli ve kaliteli ürünler elde etmek amacıyla sürekli olarak tarımsal gelişim göstermiştir (Aksu, 2011; Aldağ vd., 2018).

Dünya Sağlık Örgütü tarafından yürütülen araştırmalar, bireylerin beslenme durumu ile ülkelerin kalkınmışlık düzeyi arasında doğrudan bir ilişki olduğunu ortaya koymaktadır. Gelişmişlik düzeyi düşük olan ülkelerde besin kaynaklarına erişim kısıtlıdır ve bu durum, nüfusun önemli bir kesiminin açlık sınırında yaşamını sürdürmesine neden olmaktadır. Açlık ve yetersiz beslenme, küresel düzeyde ciddi bir tehdit oluşturarak her yıl yaklaşık 40 milyon insanın sağlık sorunları nedeniyle yaşamını yitirmesine yol açmaktadır (Yılmaz vd., 2009; Aksu, 2011). Nüfusun yeterli, dengeli ve sürdürülebilir şekilde beslenmesini temin etmek için öncelikli olarak nüfus artış hızının kontrol altına alınması gerekmektedir. Zira hızlı nüfus artışı, mevcut kaynakların hızla tükenmesine, ekonomik kalkınmanın yavaşlamasına ve sosyal problemlerin derinleşmesine sebebiyet vermektedir (Çamurcu, 2005). Günümüzde

nüfus artış oranları ülkelerin gelişmişlik düzeylerine göre değişkenlik gösterse de küresel ortalama artış oranı yaklaşık %1.7'dir. Bu artış hızının devam etmesi durumunda, dünya nüfusunun yaklaşık 41 yıl içerisinde iki katına ulaşacağı öngörülmektedir (Çamurcu, 2005; Bayar, 2018). Nüfus artışındaki bu hız, sınırlı doğal kaynakların daha hızlı tükenmesine neden olacaktır (Uzun vd., 2018). Dünya yüzeyinin toplam 135 milyon kilometrekarelik alanının yalnızca 14 ila 15 milyon kilometrekarelik kısmı tarıma uygun niteliktedir; bu da gezegenin yaklaşık %10'una tekabül etmektedir. Bu verimli tarım alanları, günümüzde yaklaşık 5 milyar insanın beslenme gereksinimlerini karşılayabilmektedir. Küresel düzeyde tüketilen besinlerin dağılımı incelendiğinde; %73'ünün tahıllardan, %12'sinin sebze ve meyvelerden, %9'unun hayvansal ürünlerden ve %6'sının diğer gıda gruplarından oluştuğu görülmektedir (Aksu, 2011).

Nüfus artışı ve sınırlı tarım alanları sorununa ek olarak, kırsal alanlardan kent merkezlerine yönelen yoğun göç hareketleri de tarımsal üretimi olumsuz etkilemektedir (Aldağ vd., 2018). Kırsaldan kente göç, üretici nüfusun azalmasına neden olarak gıda üretiminde ciddi düşüşlere yol açmakta ve bu durum, artan nüfusla birlikte gıda talebini karşılamayı giderek daha güç hâle getirmektedir. Buna ek olarak, ormanların tahribi, toprak erozyonu, tarım arazilerinin yanlış ve verimsiz kullanımı, aşırı otlatma gibi çevresel bozulmalar ile bilinçsiz gübreleme uygulamaları, tarımsal üretimdeki azalışın başlıca nedenleri arasında yer almaktadır (Kılavuz ve Erdem, 2019; Güzel ve Okatan, 2022). Özellikle İkinci Dünya Savaşı sonrasında sanayileşmenin hız kazanmasıyla birlikte ortaya çıkan çevresel problemler, insan-doğa dengesini ciddi biçimde sarsmış; bu dengesizlik zamanla yalnızca ekolojik değil, sosyoekonomik boyutta da küresel çapta sorunlar doğurmuştur. Bu gelişmeler, yalnızca yerel değil küresel bir farkındalık yaratmış ve pek çok ülkeyi sürdürülebilir çözümler üretme yönünde politikalar geliştirmeye sevk etmiştir (Tıraş, 2012; Aydın Eryılmaz ve Kılıç, 2018).

Sanayileşme ve çevresel tahribatın tarımsal üretim üzerindeki olumsuz etkilerinin giderek belirginleştiği bu dönemlerde, doğanın dış müdahalelere karşı kendini onarma kapasitesinin sınırlı olduğu da anlaşılmıştır. Bu bağlamda çevrenin korunması, yalnızca ekolojik değil aynı zamanda insani bir sorumluluk olarak ele alınmalıdır (Aydın Eryılmaz ve Kılıç, 2018). Bu farkındalığın bir sonucu olarak, 20. yüzyılın

ikinci yarısında gerçekleşen ve "Yeşil Devrim" olarak adlandırılan Tarım 2.0 süreci, tarımsal üretimde ciddi bir sıçrama dönemi olarak kayıtlara geçmiştir (Çetiner, 2011; Baydar, 2015; Ercan vd., 2019). Bu dönemde, yüksek verimli ve çeşitliliği artırılmış bitki türlerinin geliştirilmesiyle birlikte üretimde kayda değer artışlar sağlanmış; gübreleme, pestisit kullanımı, modern sulama yöntemleri ve mekanizasyon gibi birçok alanda önemli ilerlemeler kaydedilmiştir. Ayrıca, zararlı organizmalarla mücadelede bilimsel yaklaşımların benimsenmesi, otomasyon sistemlerinin yaygınlaşması ve periyodik tarım uygulamalarının yerleşmesi, bu dönemin verimlilik artışında belirleyici rol oynamıştır (Çetiner, 2011; Baydar, 2015). Ancak izleyen yıllarda, dünya nüfusunun kontrolsüz biçimde artması, bu devrimin kazandırdığı ivmenin azalmasına neden olmuştur. Verimli üretim artışının yavaşlaması, tarım alanlarının bilinçsizce tahribi ve ekilebilir arazilerin artırılmasının sınırlı olması, mevcut tehditlerin boyutunu daha da artırmıştır (Çetiner, 2011). Bu çerçevede, toprak verimliliğini artırma amacıyla artan girdi kullanımı, günümüzde yanlış sulama ve aşırı gübreleme gibi ciddi çevresel problemlere yol açmaktadır (Temizel ve Koç, 2015). Geleneksel tarım uygulamalarının, artan nüfusun ihtiyaçlarını karşılamada yetersiz kalması; üreticiler üzerinde tarımsal sürdürülebilirlik baskısı oluşturmakta, çevresel riskleri artırmakta ve gıda güvenliğini tehdit eden bir unsur hâline gelmektedir. Tüm bu nedenler, tarımda teknolojik gelişmeleri takip etmenin artık bir tercih değil, zorunluluk hâline geldiğini göstermektedir (Ercan vd., 2019).

Tarımda teknolojik gelişmelere duyulan ihtiyaç giderek artarken, bu gereksinime yanıt olarak geliştirilen yenilikçi yöntemlerden biri de hassas tarım uygulamalarıdır. Üçüncü tarım devrimi olarak kabul edilen bu yaklaşım, tarladaki toprak özelliklerinin analizine dayanarak bitkilerin ihtiyaç duyduğu gübre, ilaç ve sulama gibi girdilerin doğru zamanda, doğru miktarda uygulanmasını esas almaktadır. Teknolojideki hızlı ilerlemeler sayesinde, düşük maliyetle yüksek verim elde etmeyi hedefleyen bu sistem, kimyasal girdilerin bilinçli kullanımını teşvik etmekte; işletme yönetimi, yetiştiricilik stratejileri ve tarımsal veri kayıt sistemlerinde önemli bir dönüşüm sağlamaktadır. Aynı zamanda, çevre dostu üretim anlayışını merkeze alarak sürdürülebilirliği önceleyen bir üretim modeli sunmaktadır. Hassas tarım kapsamında yürütülen çalışmalar incelendiğinde; toprak yapısının detaylı analiz edilmesi, gübreleme miktar ve yöntemlerinin optimize edilmesi, ürün veriminin izlenmesi ve sulamanın verim

üzerindeki etkilerinin değerlendirilmesi gibi çok boyutlu uygulama alanlarının öne çıktığı görülmektedir (Emekli ve Topakçı, 2009; Temizel ve Koç, 2015).

Tarımda teknolojik uygulamaların yaygınlaşması çevresel sürdürülebilirlik açısından önemli kazanımlar vadetse de mevcut üretim pratiklerinin yol açtığı tahribat yalnızca toprakla sınırlı kalmamaktadır. Yanlış tarımsal uygulamalar, özellikle de kontrolsüz gübreleme ve pestisit kullanımı gibi etkenler, su kaynakları üzerinde de ciddi baskılar oluşturmaktadır (Çetiner, 2011; Kılavuz ve Erdem, 2019). Yeryüzünün yaklaşık dörtte üçü suyla kaplı olmasına rağmen, bu kaynakların yalnızca %0.74'ü içilebilir niteliktedir. Ne var ki çevre bilincinin yetersiz oluşu ve hızla artan nüfusun etkisiyle bu sınırlı kaynaklar gün geçtikçe daha fazla zarar görmekte; su kirliliği ve kaynak tükenmesi küresel ölçekte tehdit hâlini almaktadır. Uzmanların öngörülerine göre, hızla artan su talebi ile temiz su arzı arasındaki denge 2030 yılı itibarıyla kritik bir eşik noktasına ulaşacaktır. Bu eğilim, gerekli önlemler gecikirse, tüm dünyayı etkileyebilecek boyutta bir su krizine yol açabilir (Akın ve Akın, 2007). Tarım sektörü, sanayiyle birlikte en yüksek su tüketen sektörlerden biridir. Özellikle yerüstü ve yeraltı su kaynakları, yoğun tarımsal faaliyetler nedeniyle kirlenme riski altındadır. Türkiye'nin yıllık kullanılabilir su potansiyeli 110 milyar m^3 civarındayken, bunun yalnızca 40 milyar m^3'ü etkin biçimde değerlendirilebilmektedir. Kullanımın yaklaşık %75'i tarımsal sulamaya ayrılmakta, %15'i içme ve kullanma amaçlı tüketilmekte, kalan %10'u ise sanayi sektöründe değerlendirilmektedir (Aras, 2006; Bayrakçı vd., 2021). Bu durum, sadece ülkemiz özelinde değil, küresel çapta da benzer eğilimlerle karşılaşıldığını göstermektedir. İklim değişikliğinin şiddetlenmesi, kullanılabilir su kaynaklarının hızla azalması ve tarım arazilerinin sistematik biçimde tahrip edilmesi, günümüz tarım politikalarının yeniden yapılandırılmasını zorunlu kılan başlıca nedenler arasındadır (Bayrakçı vd., 2021).

Su ve toprak kaynaklarının sınırlı oluşu ile birlikte, artan nüfusun tarımsal ürün talebini karşılamak her geçen gün daha karmaşık hâle gelmektedir. Bu durum, mevcut üretim alanlarının yetersizliği nedeniyle, üreticileri yüksek verim hedefiyle alternatif yöntemler geliştirmeye yöneltmiştir. Özellikle kimyasal gübre ve pestisit gibi yoğun girdilere dayalı üretim sistemleri, kısa vadede verim artışı sağlasa da uzun vadede hem çevresel dengeyi bozmuş hem de insan sağlığı üzerinde olumsuz etkiler yaratmıştır. Bu sorunların önüne geçebilmek amacıyla, doğal kaynakların korunması ve halk

sağlığının güvence altına alınması hedefiyle sürdürülebilir tarım sistemleri geliştirilmeye başlanmıştır. Sürdürülebilir tarım; çevreyi, insan sağlığını ve üretim kaynaklarını gözeten, teknoloji destekli üretim sistemlerinin bütününü ifade etmektedir. Bu yaklaşım, ekonomik kârlılık, sosyal sorumluluk ve çevresel sürdürülebilirlik olmak üzere üç temel ilkeye dayanmaktadır (Musanase vd., 2023). Sürdürülebilir tarım uygulamaları kapsamında; ürün deseninin çeşitlendirilmesiyle toprak sağlığının korunması, bitki hastalıklarının önlenmesi yoluyla verimliliğin artırılması, yabancı ot ve zararlıların kontrol altına alınması, kimyasal girdi kullanımının azaltılması ve üreticilerin teknik bilgi düzeylerinin yükseltilmesi gibi birçok yöntem öne çıkmaktadır (Ikhlaq ve Kechadi, 2023; Patel ve Patel, 2023). Bu sistemler, hem toprak ve su kaynaklarının verimli kullanılmasını sağlamakta hem de sentetik girdilerin sınırlandırılması yoluyla tarımın doğaya zarar vermeden sürdürülmesine olanak tanımaktadır. Sürdürülebilirlik ilkeleri doğrultusunda yapılan üretim, yalnızca tarımsal verimliliği artırmakla kalmayıp aynı zamanda yaşam kalitesine ve çevresel istikrara da katkı sunmaktadır. Türkiye özelinde değerlendirildiğinde ise sürdürülebilir tarımın; erozyonun önlenmesi, aşırı kimyasal kullanımının azaltılması, çevre kirliliğinin engellenmesi, su kaynaklarının korunması, kırsal alanlardaki kentleşme ve turizmin etkilerinin sınırlandırılması ve mera ile çayır alanlarının daha etkin yönetilmesi gibi pek çok alanda somut fayda sağladığı görülmektedir (Patel ve Patel, 2023).

Sürdürülebilir tarım anlayışının teknolojik gelişmelerle birleşmesi sonucu ortaya çıkan Tarım 4.0 kavramı, tarımda dijitalleşme sürecinin bir yansıması olarak değerlendirilmektedir. 2010'lu yılların başlarında şekillenmeye başlayan bu dördüncü tarım devrimi, üretkenliği ve kaynak kullanım verimliliğini artırmayı hedefleyen, yüksek teknoloji temelli bir tarımsal üretim modelidir (Rehber ve Turhan, 2002; Kılavuz ve Erdem, 2019; Güzel ve Okatan, 2022). Bu bağlamda; sensör teknolojileri, robotik sistemler, yapay zekâ algoritmaları ve makine öğrenmesi yaklaşımları tarımsal süreçlerde etkin biçimde kullanılmaya başlanmıştır. Diğer sektörlerde olduğu gibi, tarım alanında da yapay zekâ araştırmaları ivme kazanmış; bu teknolojiler aracılığıyla tarımsal işlemler hem daha verimli hâle gelmiş hem de sorunlara daha hızlı ve etkili çözümler üretilebilmiştir (Terzi vd., 2019; Güzel ve Okatan, 2022). Yapay zekâ uygulamaları; hasat ve ürün yönetimi, sulama stratejileri, bitki hastalıklarının erken teşhisi ve yabancı ot kontrolü gibi çeşitli alanlarda yaygınlık kazanmıştır. Bu

gelişmeler, tarımda yalnızca mekanikleşmenin değil aynı zamanda dijital karar destek sistemlerinin de önem kazandığını göstermektedir. Tarım 4.0'ın temel amacı, üreticilerin kararlarını deneyim veya sezgilere değil, nesnel veriye ve analitik bilgiye dayalı olarak almasını sağlamak; böylelikle tarımsal faaliyetleri daha sürdürülebilir, öngörülebilir ve yönetilebilir bir hâle getirmektir (Aldağ vd., 2018; Ikhlaq ve Kechadi, 2023; Musanase vd., 2023; Patel ve Patel, 2023).

Tarım 4.0 yaklaşımının küresel ölçekte hızla yaygınlaşması, Türkiye'de de tarım sektörünü dönüşüme zorlamış ve bu dönüşüm süreci her geçen gün daha görünür hâle gelmiştir. Ülke ekonomisine doğrudan katkı sağlayan stratejik bir sektör olarak tarım, yapay zekâ destekli teknolojiler ve Endüstri 4.0 ilkeleri doğrultusunda yeniden şekillenmektedir (Uzun vd., 2018; Güzel, 2022). Geleneksel üretim yöntemleri, artan nüfusun besin ihtiyacını karşılamakta yetersiz kalmakta; buna bağlı olarak tarımsal faaliyetlerin çevresel etkileri de giderek artmaktadır. Bu durum, sürdürülebilirlik ilkesinin yalnızca bir tercih değil, zorunluluk hâline geldiğini açık biçimde ortaya koymaktadır. Bu nedenle, tarımsal üretimde yenilikçi ve teknolojik çözümlerin benimsenmesi kaçınılmazdır. Bu bağlamda, akıllı tarım teknolojileri ve dijital sistemler, Türkiye'de de tarımsal süreçlerin iyileştirilmesi ve verimliliğin artırılması amacıyla yaygın biçimde kullanılmaya başlanmıştır (Uzun vd., 2018; Ercan vd., 2019; Güzel ve Okatan, 2022).

Tarım 4.0 yaklaşımı doğrultusunda yapay zekâ destekli sistemlerin benimsenmesiyle, tarımsal faaliyetlerde önemli dönüşümler yaşanmaya başlanmıştır. Yapay zekâ teknolojileri, farklı sektörlerde yaygın biçimde kullanılsa da tarım sektörünün bu teknolojilere adaptasyonu nispeten daha yavaş gerçekleşmiştir. Ancak son yıllarda, yapay zekânın üretim süreçlerine entegre edilmesiyle birlikte tarım alanında da kayda değer ilerlemeler sağlanmıştır (Uzun vd., 2018). Özellikle hasat ve ürün yönetimi, üretim sürecinin planlanması, bitki hastalıklarının erken dönemde tespiti, sulama ve gübreleme döngülerinin optimize edilmesi, verimlilik tahminlerinin yapılması, yabancı ot kontrolü ve tarım robotları aracılığıyla uygulama kararlarının otomatikleştirilmesi gibi alanlarda yapay zekâ sistemlerinin etkin biçimde kullanıldığı gözlemlenmektedir (Uzun vd., 2018; Terzi vd., 2019; Güzel ve Okatan, 2022). Bu uygulamalar sayesinde, geleneksel tarım yöntemlerinin sınırları aşılmış; daha verimli, öngörülebilir ve sürdürülebilir bir üretim modeli ortaya konulmuştur.

Tarım sektörüne dijital teknolojilerin entegre edilmesi, yalnızca üretim süreçlerinde değil, aynı zamanda kaynak yönetimi ve maliyet optimizasyonunda da çeşitli avantajlar sunmaktadır. Bu dönüşüm sayesinde ürün verimliliği artmakta, yakıt ve gübre gibi girdi maliyetlerinde azalma sağlanmakta ve su kaynakları daha etkin, sürdürülebilir biçimde kullanılabilmektedir (Kılavuz ve Erdem, 2019). Yapay zekâ temelli uygulamalar, üretimin her aşamasında veri temelli karar alma süreçlerini destekleyerek tarımsal etkinliği önemli ölçüde artırmaktadır. Bu kapsamda; ürün deseninin planlanması, mahsullerin sınıflandırılması, verimlilik tahminleri ve analizleri, uygun gübre türünün ve uygulama periyodunun belirlenmesi, sulama stratejilerinin optimize edilmesi, sera ortam koşullarının yönetilmesi, zararlı otların ve bitki hastalıklarının teşhis edilmesi ve bu sorunlara yönelik çözüm önerilerinin geliştirilmesi gibi pek çok alanda yapay zekâ sistemlerinden yararlanılmaktadır (Terzi vd., 2019). Ayrıca, tarım robotlarının sahada izleyeceği rotaların belirlenmesi gibi operasyonel karar süreçleri de bu teknolojiler aracılığıyla otomatikleştirilmiş ve insan hatasının minimize edilmesi mümkün hâle gelmiştir.

Tarımda dijital teknolojilerin sunduğu olanaklara ek olarak, doğayla uyumlu ve insan sağlığını öncelik kabul eden alternatif üretim modelleri de giderek önem kazanmaktadır. Bu doğrultuda, sürdürülebilir tarımın çevre odaklı ilkelerini daha da ileri taşıyan ve kimyasal gübre ile pestisit kullanımını tamamen yasaklayan organik tarım modeli benimsenmiştir. Çevreye duyarlı, canlı sağlığını esas alan bu üretim biçimi, bozulmuş ekolojik dengeyi yeniden inşa etmeyi hedeflemektedir (Çetiner, 2011). Organik tarım, sentetik gübre ve tarım ilaçlarının kullanımını reddederek üreticileri doğal gübreleme ve biyolojik mücadele yöntemlerine yönlendirmekte; bu yönüyle geleneksel yüksek verim odaklı sistemlerden ayrışmaktadır. Organik tarımın temel amacı, nicelikten çok nitelik öncelikli üretim yaparak elde edilen ürünlerin sağlığa zarar vermeyecek şekilde, doğal girdilerle yetiştirilmesini sağlamaktır (Turan, 2022). İnsana ve doğaya dost bu yaklaşım hem çevresel hem de sosyal sürdürülebilirliği destekleyen bir üretim sistemi olarak dünya genelinde yaygınlık kazanmış; günümüzde yaklaşık 24 milyon hektarlık alanda uygulanır hâle gelmiştir (Rehber ve Turhan, 2002).

Tarım sektöründe teknolojik gelişmelerin ve çevre dostu üretim modellerinin benimsenmesi, yalnızca üretim araçlarının dönüşümünü değil, aynı zamanda üretici

davranışlarının da yeniden şekillenmesini zorunlu kılmaktadır. Nitekim dünya genelinde tarım sektörü, iş gücünün yaklaşık %75'ini istihdam etmekte olup, bu büyük orana rağmen üreticilerin bilinçsiz veya geleneksel yaklaşımlarına dayalı tutumları, verim kaybına ve dolayısıyla kârlılıkta düşüşe neden olmaktadır (Türkoğlu, 1958; Yılmaz vd., 2009; Aksu, 2011; Uzun vd., 2018). Bu çerçevede, dengeli gübreleme uygulamalarının temelini oluşturan toprak analizi, bitkilerin ihtiyaç duyduğu besin elementlerinin belirlenmesine imkân tanımakta ve böylece gübre kullanımının daha bilinçli şekilde planlanmasını sağlamaktadır. Her bitkinin farklı düzeyde besin elementi gereksinimi olduğu göz önünde bulundurulduğunda, gübrelemenin toprak analizine dayandırılması bilimsel bir zorunluluk hâline gelmektedir (Yılmaz vd., 2009). Örneğin Isparta ilinde gerçekleştirilen bir araştırmada, üreticilerin büyük bir çoğunluğunun gübreleme uygulamalarını herhangi bir analiz yaptırmaksızın gerçekleştirdiği saptanmıştır. Çalışmaya göre, gübre miktarını belirleyen üreticilerin %33.67'si, gübre türünü seçenlerin %37.76'sı ve gübreleme zamanına karar verenlerin %36.73'ü bu kararları tamamen kişisel deneyimlerine dayalı olarak almaktadır. Dahası, üreticilerin %21.43'ü hangi ürüne, ne miktarda ve hangi sıklıkta gübre verilmesi gerektiği hakkında yeterli bilgiye sahip değildir. Analiz verilerine dayalı gübreleme yapan üretici oranı sadece %13.27 iken, hayatı boyunca hiç toprak analizi yaptırmamış üretici oranı %60.47'dir. Analiz yaptırmama gerekçeleri arasında; %30.14'lük bir kesim analiz ihtiyacını gereksiz bulurken, %20.15'i maliyetleri yüksek, %19.18'i sonuçları güvenilmez, %16.44'ü örnek alma yöntemini bilmediğini ve %13.70'i sürecin uzun sürdüğünü ifade etmiştir. Gübre türü seçiminde ise üreticilerin %15.31'i çevresel etkilerden (komşu, bayi, akraba) etkilenmekte, yalnızca %13.27'si kamu kurumlarının önerilerini dikkate almakta, %12.24'ü toprak analiz sonuçlarını temel almakta ve %6.12'si kooperatiflerden bilgi almaktadır (Yılmaz vd., 2009). Bu bulgular, gübreleme süreçlerinin yalnızca tarımsal üretimin verimliliği için değil, aynı zamanda çevresel sürdürülebilirlik ve ekonomik kazanç açısından da ne denli kritik olduğunu göstermektedir. Dolayısıyla üreticilerin modern tarım bilgileriyle donatılması kaçınılmazdır. Bu bilinçlendirme süreci, mesleki eğitim programlarına yönlendirme ve üreticilerin bilgi-beceri düzeylerinin artırılması yoluyla başlatılmalıdır. Bilgiyle donatılmış bir üretici hem ürün kalitesini yükseltebilir hem de daha avantajlı fiyatlarla pazarlama imkânı bularak hem kendi refahını hem de ülke ekonomisini olumlu yönde etkileyebilir (Türkoğlu, 1958).

Tarımsal üretimde elde edilen verim, yalnızca üreticinin müdahalesiyle değil; büyük ölçüde çevresel ve biyolojik etkenlerle de şekillenmektedir. Özellikle toprak yapısı, bitki örtüsü, topoğrafik özellikler ve iklim gibi doğal koşullar, mahsul verimini doğrudan etkileyen kritik faktörler arasında yer almaktadır. Bu çevresel unsurların yanı sıra, bitkinin biyolojik yapısı da ürün miktarının ve kalitesinin belirlenmesinde önemli rol oynamaktadır. Bitkinin gelişimini desteklemek ya da biyolojik sınırlılıklarını ortadan kaldırmak amacıyla başvurulan kimyasal gübre ve tarımsal ilaçlar, uygulama yöntemi ve dozajına bağlı olarak tarımsal çıktılar üzerinde doğrudan belirleyici olabilmektedir (Gilden vd., 2010; Tiryaki vd., 2010; Şahin, 2016). Ancak yüksek verim beklentisiyle yapılan yoğun kimyasal kullanımının, uzun vadede çevresel tahribatı beraberinde getirdiği görülmektedir. Özellikle gereğinden fazla uygulanan kimyasallar, toprak ve su kaynaklarının kirlenmesine yol açmakta; bu durum, sürdürülebilir üretim ilkeleriyle çelişen sonuçlar doğurmaktadır. Bilinçsiz gübreleme uygulamaları sonucunda, toprakta tuzluluk ve ağır metal birikimi artmakta; besin elementlerinin dengesi bozulmakta, azot ve kükürt gibi gazların atmosfere salınımı hızlanmakta; ayrıca topraktaki mikrobiyal faaliyetler olumsuz yönde etkilenmektedir. Bu olumsuzluklar yalnızca tarımsal üretimi değil, aynı zamanda içme sularında kimyasal kalıntıların birikmesine neden olarak hem insan sağlığı hem de ekosistem açısından ciddi tehditler oluşturmaktadır (Sönmez vd., 2008; Çetiner, 2011; Temizel ve Koç, 2015; Aydın Eryılmaz vd., 2019).

Bitkisel üretimde yüksek verim ve kaliteli ürün elde edebilmek için, her bitki türünün gelişim sürecinde ihtiyaç duyduğu besin elementlerinin doğru ve yeterli miktarda sağlanması büyük önem taşımaktadır. Ancak bu ihtiyaçların karşılanmasında yalnızca eksiklik değil, aşırılık da ciddi sorunlara yol açabilmektedir. Zira belirli besin elementlerinin fazlası, bitki fizyolojisini olumsuz etkileyerek gelişim sürecini sekteye uğratabilir. Bu nedenle gübreleme sürecinin rastlantısal değil, bilimsel verilere dayalı şekilde yürütülmesi, üreticiler açısından temel bir strateji olmalıdır (Yağmur, 2009; Baran vd., 2021). Bu bağlamda, toprakta doğal olarak bulunan ve bitkisel üretimde hayati rol oynayan bazı temel besin elementlerine değinmek gerekirse:

Bitki beslenmesinde hayati öneme sahip olan potasyum, bitki dokularında yüksek yoğunlukta bulunan ve hem ürün miktarını hem de kaliteyi doğrudan etkileyen bir makro besin elementidir. Özellikle büyüme ve gelişme dönemlerinde yoğun olarak

topraktan alınan potasyum; nitrat ve fosforun emilimini düzenleyerek besin alım dengesini korur, su kaybını önleyerek turgor basıncının sağlanmasına katkı sunar. Aynı zamanda protein sentezini destekler, kök gelişimini uyarır, bitkinin düşük sıcaklık stresine ve patojen kaynaklı hastalıklara karşı direncini artırır. Potasyumun bu rolleri, yalnızca verimi değil, bitkinin genel sağlığını ve çevresel koşullara adaptasyon yeteneğini de olumlu yönde etkilemektedir (Yağmur, 2009; Zebec vd., 2017).

Toprak kalitesini belirleyen temel bileşenlerden biri olan organik madde hem verimlilik hem de toprak canlılığı açısından kritik bir rol oynamaktadır. Organik madde, toprakta yaşayan mikroorganizmalar için başlıca enerji ve besin kaynağını oluşturmakta; bu sayede mikrobiyal faaliyetleri teşvik ederek toprak ekosisteminin işleyişini desteklemektedir. Organik madde bakımından zengin topraklar, yapısal olarak daha iyi havalanmakta, ısıyı daha hızlı iletmekte ve yüksek su tutma kapasitesi sayesinde kök gelişimini doğrudan desteklemektedir. Ancak Türkiye topraklarının yaklaşık %65'i, özellikle iklim koşulları başta olmak üzere çeşitli çevresel etkenlere bağlı olarak organik madde açısından yetersiz düzeydedir (Yaraş ve Daşgan, 2012; Baran vd., 2021; Turan, 2022).

Toprağın kimyasal özelliklerinden biri olan pH değeri, asitlik ya da alkalilik düzeyini ifade eden temel bir göstergedir ve bitki besin elementlerinin emiliminde belirleyici bir rol oynar. Bitkilerin besin maddelerine erişimi büyük ölçüde pH seviyesine bağlı olduğundan, bu parametre tarımsal verimliliğin doğrudan bir belirleyicisi olarak kabul edilmektedir. Aynı zamanda pH, toprak ekosisteminde yer alan mikroorganizmaların aktivitelerini de etkileyerek toprak biyolojisi üzerinde kritik etkiler yaratır. Asidik özellik gösteren topraklarda hidrojen iyonu (H^+), alkali ortamlarda ise hidroksit iyonu (OH^-) baskın hâle gelir. Toprak çözeltisindeki bu iyonik denge, hem besin maddelerinin bitki tarafından alına bilirliğini hem de toprak sağlığını şekillendiren temel bir unsurdur (Yaraş ve Daşgan, 2012; Moonrungsee vd., 2015).

Fosfor, bitki gelişimi ve tarımsal verimlilik açısından hayati öneme sahip temel makro besin elementlerinden biridir. Bitkinin enerji transferi, hücre bölünmesi ve kök gelişimi gibi fizyolojik süreçlerinde aktif rol oynayan bu element, tarımsal üretimde kaliteyi ve dayanıklılığı artıran başlıca faktörlerdendir. Fosforun topraktaki varlığı laboratuvar ortamında belirlenebilmekte; ancak bu analizler genellikle maliyetli olup

uzmanlık gerektiren yöntemlerle gerçekleştirilmektedir. Öte yandan, fosfor yalnızca bitki beslenmesi açısından değil, çevresel sürdürülebilirlik açısından da kritik bir bileşendir. Özellikle suda çözünmüş formu, su kaynaklarının kalitesini doğrudan etkilemekte; yüksek fosfor düzeyleri, çevresel sorunlara yol açarak ekosistem dengelerini bozabilmektedir (Moonrungsee vd., 2015; Islam vd., 2016).

Bu çalışmanın yürütüldüğü Isparta ili, Türkiye'nin önemli tarımsal üretim merkezlerinden biri olup, yoğun tarımsal faaliyetlerin sürdürüldüğü verimli bölgeler arasında yer almaktadır. Akdeniz ve Karadeniz iklim tipleri arasında bir geçiş kuşağında konumlanan il, her iki iklimin özelliklerini bünyesinde barındırması sayesinde zengin bir tarımsal çeşitliliğe sahiptir. Yıllık ortalama yağış miktarı 506 kg/m² düzeyindedir ve bu yağışların yaklaşık %68.8'i kış ve ilkbahar aylarında gerçekleşirken, yaz ve sonbahar dönemleri genellikle kurak geçmekte ve yağış oranı %31.2 seviyelerinde kalmaktadır. Isparta'nın yüzey şekilleri dikkate alındığında, arazisinin yaklaşık %42'si meşe, kızılçam, karaçam, sedir ve ardıç gibi orman örtüsüyle kaplıdır. Tarımsal faaliyetlerin yürütüldüğü alanlar ise toplam arazinin yaklaşık %28'ini oluşturarak yaklaşık 251 000 hektarlık bir yüzölçümüne sahiptir. Bölgede yaygın olarak karşılaşılan başlıca toprak tipleri arasında kahverengi orman toprakları, kalkersiz kahverengi orman toprakları, kırmızı ve kırmızımsı kahverengi akdeniz toprakları ile kestane renkli topraklar bulunmaktadır. Isparta tarımında meyvecilik öne çıkan sektörlerden biri olup, özellikle elma üretimi (yıllık yaklaşık 500 bin ton) bölge ekonomisine önemli katkı sağlamaktadır. Bunun yanı sıra kiraz (yaklaşık 17 bin ton), üzüm, gül, vişne ve kayısı gibi ürünlerin de üretimi yaygın biçimde gerçekleştirilmektedir (Bilir, 2010).

1.2. Yapay Zekâ Teknolojisi

Yapay zekâ, ilk olarak John McCarthy tarafından, "zeki makineler özellikle de zeki bilgisayar programları yapma bilimi ve mühendisliği" şeklinde tanımlanmıştır (Demirhan vd., 2010). Yapay zekâ, bilgisayar destekli bir makinenin görme, düşünme, planlama, karar verme, algılama, hareket etme gibi insana özgü nitelikler ile görevleri yerine getirme yeteneğidir (Bozüyük vd., 2005; Öztürk ve Şahin, 2018; Uzun vd., 2018; Çakmakçı ve Çakmakçı, 2023). İnsan zekâsını taklit etmeye programlı bu teknolojiler bilgisayar biliminin temel araştırma dallarından biridir (Bozüyük vd.,

2005; Uzun vd., 2018; Güzel ve Okatan, 2022; Çakmakçı ve Çakmakçı, 2023). Yapay zekânın hayatımıza en büyük katkısı öğrenme becerisidir, yani öğrendiği en doğru yolu en hızlı şekilde uygulamaya geçirebilme kabiliyetidir. Birçok disiplinin bir araya gelmesinden meydana gelen yapay zekâ bilimi bünyesinde bilgisayar mühendisliği, kontrol, mekatronik, felsefe, elektronik, programlama gibi alanları bulundurur (Öztürk ve Şahin, 2018). Hayatın içinde pek çok alanda yer alan yapay zekâ tahminleme, sınıflandırma ve kümeleme gibi amaçlar için de kullanılır (Atalay ve Çelik, 2017; Aylak vd., 2021). Yapay zekânın tarım sektöründeki kullanım alanlarını örneklemek gerekirse; bitkilerdeki hastalıkların teşhisi, istenmeyen ot ve haşere yönetimi, su kaynaklarını kullanım, ürün verimlilik analizi, gübreleme, çevrenin mahsule etkileri, iklim koşulları vb. şeklinde çoğaltılabilir (Ryan vd., 2023).

1.2.1. Yapay zekâ teknolojisinin tarihsel gelişimi

Yapay zekâ (YZ) kavramı, sanılanın aksine oldukça eskiye dayanan bir geçmişe sahiptir. Gelişimi aşağıdaki kronolojiyle özetlenebilir:

1884: Charles Babbage, bazı makinelerin insanlar kadar zeki olamayacağını bilse de belirli davranışları gerçekleştirmesini hedefleyen çalışmalar yapmıştır.
1921: Karel Čapek, R.U.R. (Rossum's Universal Robots) adlı tiyatro oyununda yapay zekaya sahip robotlar ve insanların ortak sorunlarını ele alan bir gösteri hazırlamıştır. Bu eserle birlikte “robot” terimi ilk kez kullanılmıştır.
1941: Elektronik bilgisayarların geliştirilmesiyle, makinelerin zekâ ile bütünleştirilmesi fikri gündeme gelmiştir.
1943: Warren McCulloch ve Walter Pitts, tarafından nöronların Boolean (mantıksal) devrelerle temsil edilebileceğini öne sürerek insan beyninin çalışma biçimini taklit eden ilk matematiksel modeli geliştirmiştir. Böylece yapay sinir ağlarının temelleri atılmıştır.
1950: Claude Shannon, bilgisayarların satranç oynayabileceğini ileri sürmüştür. Aynı yıl Alan Turing, “Computing Machinery and Intelligence” adlı makalesinde “Makineler düşünebilir mi?” sorusunu gündeme getirerek Turing Testi'ni önermiştir. Bu çalışma, yapay zekânın felsefi ve kuramsal temelini oluşturmuştur.
1951: Marvin Minsky ve Dean Edmonds, yapay sinir ağlarına dayalı ilk bilgisayar olan SNARC’ı geliştirmiştir.

1956: Yapay zekâ alanının doğuşu kabul edilen Dartmouth Konferansı düzenlenmiştir. “Yapay zekâ” terimi ilk kez burada kullanılmış ve katılımcılar alanın öncüleri olarak kabul edilmiştir. Konferansta ayrıca Newell ve Simon tarafından ilk kuram ispatlayan program olan Logic Theorist’i tanıtmıştır.

1965: John Alan Robinson, formel mantık tabanlı çıkarım sistemleri için temel algoritmaları geliştirerek otomatik akıl yürütmeye önemli katkılarda bulunmuştur.

1966–1973: Veri eksikliği ve sınırlı hesaplama gücü nedeniyle yapay zekâ çalışmaları duraklamış, bu dönem literatürde "ilk yapay zekâ kışı" (AI Winter) olarak anılmıştır.

1970–1975: Tıbbi tanı sistemleri gibi kritik uygulamalar geliştirilmeye başlanmış ve bu çalışmalar yapay zekânın potansiyelini göstermiştir.

1975–1980: Rönesans sonrası dönemde, yapay zekâ araştırmaları psikoloji ve dil bilim gibi disiplinlerle etkileşime geçmiştir.

1980: Uzman sistemlerin endüstride kullanılmaya başlanmasıyla yapay zekâ sanayiye entegre olmuştur.

1986: Geri yayılım (backpropagation) algoritmasının geliştirilmesi ve hesaplama gücündeki artış sayesinde yapay sinir ağları yeniden önem kazanmıştır.

1987: Yapay zekâ, bağımsız bir bilimsel araştırma alanı olarak tanınmaya başlamış; üniversitelerde bu alana yönelik bölümler açılması tetiklenmiştir.

1995: “Zeki ajanlar” kavramı ortaya çıkmış; bu ajanlar çevrelerini algılayabilen ve hedef odaklı kararlar alabilen otonom yazılımlar olarak tanımlanmıştır.

1997: IBM’in geliştirdiği Deep Blue yazılımı, dünya satranç şampiyonu Garry Kasparov’u yenerek yapay zekâ alanında sembolik bir zafer kazanmıştır.

1998: İnternetin yaygınlaşmasıyla birlikte yapay zekâ uygulamaları günlük yaşama entegre olmaya başlamıştır. Böylece daha çok kullanıcı kitlesine ulaşmıştır.

2000–2005: Robot oyuncaklar, akıllı ev sistemleri ve otomobiller gibi birçok alanda yapay zekâ destekli ürünler piyasaya sürülmüştür. Aynı zamanda cep telefonları, akıllı ev sistemleri ve otomobiller gibi birçok teknolojik cihazda da yapay zekâ uygulamaları kullanılmaya başlanmıştır.

2006: Geoffrey Hinton ve ekibi, derin sinir ağları alanında önemli başarılar elde ederek görsel tanıma ve sesli komut sistemlerinde çığır açmıştır.

2012: ImageNet yarışmasında AlexNet adlı derin öğrenme modeli büyük başarı kazanmış ve bu gelişme, tıp, otomotiv ve görüntü işleme gibi alanlarda yapay zekanın yaygınlaşmasının önünü açmıştır.

2016: AlphaGo, dünya Go şampiyonu Lee Sedol'u yenerek yapay zekanın insan sezgisini taklit etme potansiyelini göstermiştir.
2020 ve Sonrası: Büyük dil modelleri (LLM'ler), metin üretimi, görsel oluşturma ve yazılım geliştirme gibi alanlarda aktif rol almaya başlamıştır. Bu gelişmeler; hukuk, eğitim, sağlık gibi birçok sektörde iş yapma biçimlerini temelden değiştiren bir dönüşüm sürecini başlatmıştır (Bozüyük vd., 2005; Pirim, 2006; Küçükönder, 2011; Aksoy vd., 2020; Uzun vd., 2021; Eker vd., 2023).

1.2.2. Yapay zekâ yöntemleri

Başlıca yapay zekâ yöntemlerini uzman sistemler, yapay sinir ağları, bulanık mantık, genetik algoritma, makine öğrenmesi olarak sıralamak mümkündür (Aldağ vd., 2018; Uzun vd., 2021).

1.2.2.1. Uzman sistemler

Uzman sistemler, belirli bir alanda uzmanlaşmış bireylerin bilgi ve problem çözme becerilerini taklit edebilen, yapay zekâ tabanlı bilgisayar uygulamalarıdır. Bu sistemler, yalnızca uzmanlar tarafından çözülebilecek karmaşık problemlere yönelik mantıksal çıkarım mekanizmaları kullanarak çözümler sunar. "Uzman sistem" olarak adlandırılmalarının temel nedeni, birden fazla uzmanın bilgi birikimini sistematik biçimde yazılıma entegre etmeleridir. İlk örneklerinden biri olan MYCIN, bakteriyel kan enfeksiyonlarının teşhisinde ve uygun antibiyotiklerin önerilmesinde kullanılmıştır. Günümüzde ise uzman sistemler; tıptan tarıma, finanstan eğitime kadar birçok alanda rutin süreçlerin izlenmesi, yönetilmesi ve otomasyonu amacıyla yaygın olarak kullanılmaktadır (Pirim, 2006; Bilir, 2010; Terzi vd., 2019; Aksoy vd., 2020; Eker vd., 2023; Ryan vd., 2023). Bir uzman sistemin yapısı Şekil 1.1 ile verilmiştir (Terzi vd., 2019).

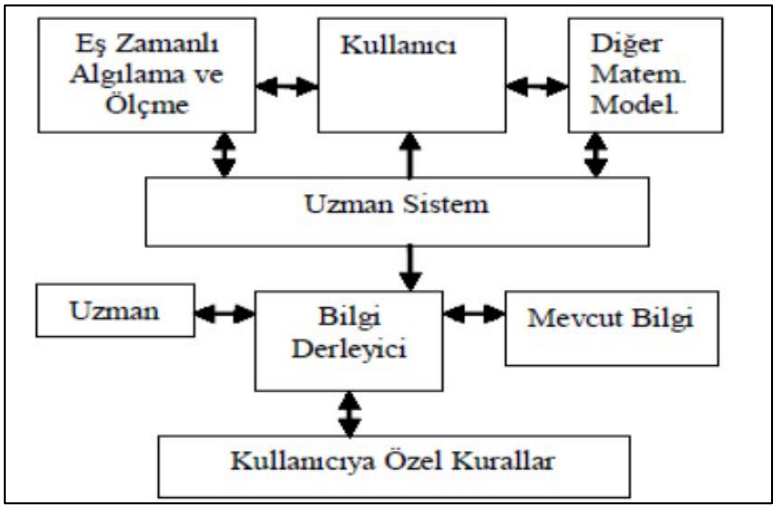

Şekil 1.1. Bir uzman sistemin iç ve dış yapısı (Terzi vd., 2019)

1.2.2.2. Yapay sinir ağları

Yapay sinir ağları, insan beynindeki nöronların yapısını model alan ve öğrenme, örüntü tanıma, genelleme gibi bilişsel süreçleri taklit etmeyi amaçlayan yapay zekâ sistemleridir. Veri filtreleme, sınıflandırma ve tahminleme gibi işlemlerde yaygın olarak kullanılan bu yapılar; çok katmanlı algılayıcılar, ileri ve geri beslemeli ağlar gibi farklı mimarilere sahiptir. Özellikle doğrusal olmayan ve çok boyutlu problemlere karşı etkili çözümler üretebilmeleri, onları geleneksel yöntemlere kıyasla daha esnek ve güçlü hâle getirmektedir. Paralel işlem yapabilme, ön bilgiye gerek duymadan öğrenme gerçekleştirme ve yeni verilerle güncellenebilme özellikleri, bu sistemlerin pratik ve sürdürülebilir yapılar sunmasını sağlamaktadır. Bununla birlikte, model kurulumunda standart bir yaklaşımın olmaması, karar mekanizmasının şeffaf olmaması ve aşırı öğrenme gibi sorunlar, yapay sinir ağlarının temel dezavantajları arasında yer almaktadır. Günümüzde bu teknolojiler; biyoloji, tıp, çevre bilimleri, finans, üretim, askerî sistemler ve iş dünyası gibi pek çok alanda karar destek ve otomasyon süreçlerini güçlendirmede etkin biçimde kullanılmaktadır. Yapay sinir ağları, karmaşık ilişkileri anlamada ve yeni durumlara uyum sağlamada sunduğu potansiyel sayesinde, disiplinler arası çalışmalarda giderek daha fazla tercih edilmektedir (Bozüyük vd., 2005; Pirim, 2006; Küçükönder, 2011; Öztürk ve Şahin, 2018; Terzi vd., 2019; Uzun vd., 2021). Yapay sinir hücresi ağı modeli Şekil 1.2 ile gösterilmiştir (Terzi vd., 2019).

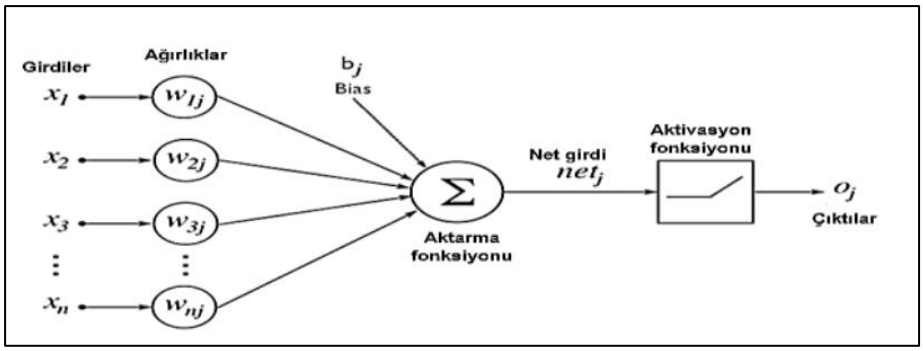

Şekil 1.2. Yapay sinir hücresi ağı (Terzi vd., 2019)

1.2.2.3. Bulanık mantık

1965 yılında Prof. Dr. Lütfi Aliasker Zade tarafından geliştirilen bulanık mantık, insan düşünme biçimini taklit eden ve belirsizlik içeren durumlarda karar verme süreçlerini iyileştiren bir matematiksel yaklaşımdır. Uç değerler ile bu değerler arasındaki geçişleri kapsayan yapısıyla, özellikle net verilerin yetersiz olduğu ortamlarda işlevseldir. Klimalar, çamaşır makineleri ve fren sistemleri gibi birçok teknolojide yaygın şekilde kullanılmaktadır. Matematiksel model zorunluluğu bulunmadığından farklı alanlara kolayca entegre edilebilir. Ancak sistem kurallarının sübjektif olması ve üyelik fonksiyonlarının deneyime dayanması, geliştirme sürecini karmaşıklaştırabilmektedir (Bozüyük vd., 2005; Öztürk ve Şahin, 2018; Terzi vd., 2019). Bulanık mantık sisteminin yapısı Şekil 1.3 ile gösterilmiştir (Memmedova, 2012).

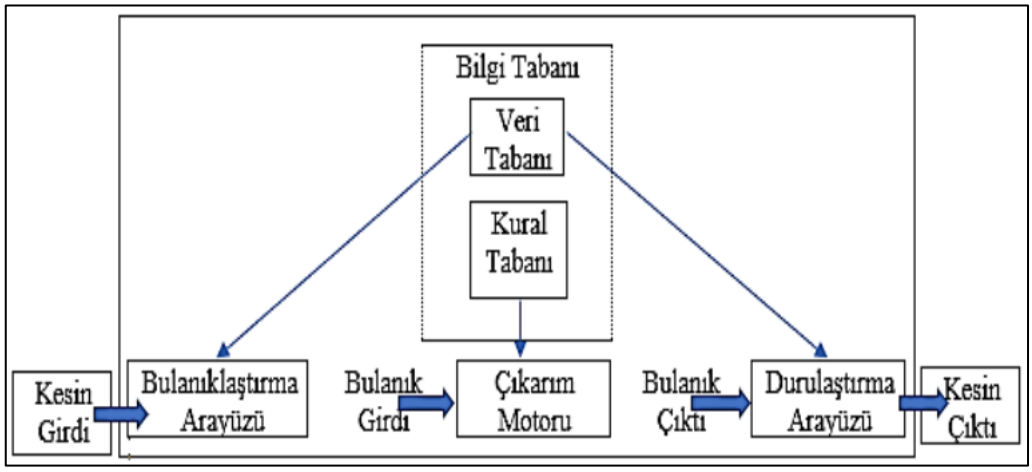

Şekil 1.3. Bir bulanık sistemin yapısı (Memmedova, 2012)

1.2.2.4. Genetik algoritma

Genetik algoritmalar, 1970'li yıllarda John Holland tarafından geliştirilmiş ve biyolojik evrim süreçlerinden esinlenerek oluşturulmuş bir optimizasyon yöntemidir. Doğal seleksiyon, çaprazlama ve mutasyon gibi evrimsel mekanizmaları taklit eden bu algoritmalar, çözüm uzayında en uygun sonuca ulaşmak amacıyla aynı anda birden fazla aday çözüm üzerinde işlem yapar. Parametreler belirli bir kod yapısına dönüştürülerek ifade edilir ve her bir çözüm, uygunluk (fitness) fonksiyonu aracılığıyla değerlendirilir. Yeni çözümler üretme süreci, rastlantısal seçimlere ve olasılık tabanlı kararlara dayanmakta olup, ön bilgiye ihtiyaç duyulmaksızın kör arama yöntemiyle gerçekleştirilir. Bu sayede, düşük kaliteli çözümler elenirken, yüksek kaliteli ve hedefe yakın çözümler sistematik biçimde çoğaltılır. Genetik algoritmalar, çözüm kalitesini sürekli iyileştirmeyi amaçlayan evrimsel yapısıyla klasik optimizasyon yöntemlerinden ayrışmaktadır. Ancak üretilen çözümlerin başarısı mutlak değildir ve sonuçlar büyük ölçüde olasılık hesaplamalarına bağlıdır (Bozüyük vd., 2005; Pirim, 2006; Küçükönder, 2011; Terzi vd., 2019; Uzun vd., 2021). Genetik algoritmanın akış şeması Şekil 1.4 ile gösterilmektedir (Terzi vd., 2019).

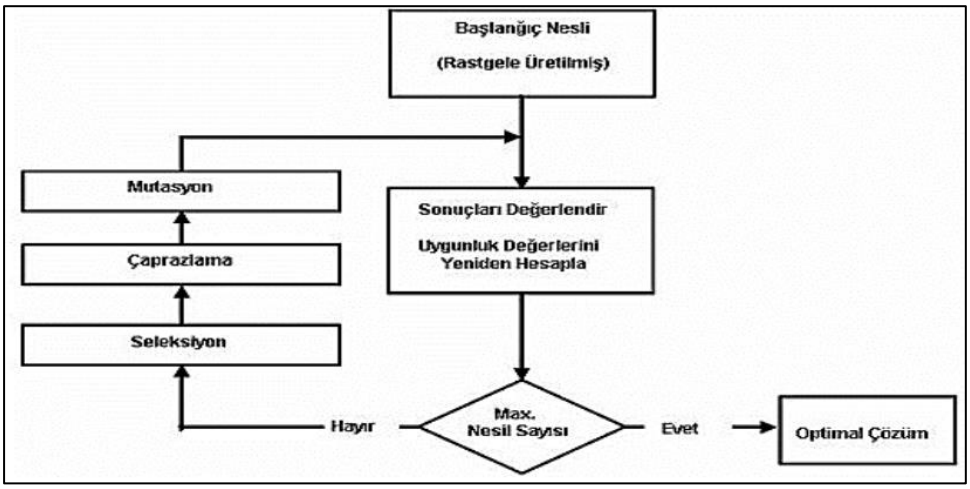

Şekil 1.4. Genetik algoritma akış şeması (Terzi vd., 2019)

1.2.2.5. Makine öğrenmesi

Günümüzde verilerin hacmi hızla artmakta ve bu veriler giderek daha karmaşık yapılara bürünmektedir. Bu durum, klasik veri analiz yöntemlerinin yetersiz kalmasına ve daha gelişmiş teknolojilere olan ihtiyacın ortaya çıkmasına yol açmıştır. Makine

öğrenmesi, bu noktada devreye girerek büyük ve karmaşık veri kümelerinden doğru ve anlamlı analizler yapılmasını mümkün kılmakta ve söz konusu analiz boşluğunu kapatmaktadır (Atalay ve Çelik, 2017; Öztürk ve Şahin, 2018; Bou Nassif vd., 2019; Gültepe, 2019; Aylak vd., 2021; Bayrakçı vd., 2021; Gökalp, 2021; Eker vd., 2023).

Yapay zekânın bir alt dalı olan makine öğrenmesi, derin öğrenmenin ise üst kümesi olarak konumlanmaktadır. Bu bağlamda, alanlar arası hiyerarşi şu şekilde sıralanmaktadır: sinir ağları → derin öğrenme → makine öğrenmesi → yapay zekâ. Bu teknoloji, açıkça programlanmaya gerek duymadan, mevcut örneklerden hareketle olayların giriş (input) ve çıkış (output) verilerini analiz eder. Ardından, bu veriler arasındaki ilişkileri keşfederek bilgisayar sistemlerinin söz konusu ilişkileri öğrenmesini sağlar (Atalay ve Çelik, 2017; Öztürk ve Şahin, 2018; Bou Nassif vd., 2019; Gültepe, 2019; Aylak vd., 2021; Gökalp, 2021; Bayrakçı vd., 2021; Eker vd., 2023).

En yüksek doğruluk ve verimliliği sağlamayı amaçlayan bu teknoloji, çeşitli makine öğrenmesi algoritmalarının geliştirilmesini beraberinde getirmiştir. Bu algoritmalar arasında k-ortalamalar algoritması, k-en yakın komşu algoritması, karar ağaçları, destek vektör makineleri, lojistik regresyon analizi ve yapay sinir ağları yer almaktadır. Bu yöntemler, farklı veri türleri ve problem yapıları için özelleştirilmiş çözümler sunmaktadır (Atalay ve Çelik, 2017; Öztürk ve Şahin, 2018; Bou Nassif vd., 2019; Gültepe, 2019; Aylak vd., 2021; Bayrakçı vd., 2021; Gökalp, 2021; Eker vd., 2023).

Bu sistemler, öğrendikleri bilgileri hafızalarında tutmakta ve benzer durumlarla karşılaşıldığında bu bilgileri kullanarak karar verebilmektedir. Makine öğrenmesinin temel amacı; tanıma, planlama, teşhis, tahmin ve kontrol gibi görevleri otomatik hâle getirerek insan müdahalesine duyulan ihtiyacı en aza indirmektir (Atalay ve Çelik, 2017; Öztürk ve Şahin, 2018; Bou Nassif vd., 2019; Gültepe, 2019; Aylak vd., 2021; Bayrakçı vd., 2021; Gökalp, 2021; Eker vd., 2023).

Makine öğrenmesi süreçleri, etkili ve güvenilir sonuçlar elde edebilmek için belirli aşamalar çerçevesinde yürütülmektedir. Başarılı bir uygulama süreci genellikle aşağıdaki temel adımları izlemektedir:

- **Veri Toplama (Data Collection):** Makine öğrenmesi sürecinin temel aşaması, modelin eğitimi için gerekli verilerin sistematik ve anlamlı şekilde toplanmasıdır. Eğitim verileri, geçmiş deneyimleri temsil etmeli ve modelin kullanılacağı koşulları yansıtacak şekilde standartlaştırılmalıdır.

- **Özellik Oluşturma (Feature Engineering):** Bu aşama, veriden anlamlı ve ayırt edici bilgilerin elde edilerek modelin kullanımına sunulmasını içerir. Nitelikli özellikler, modelin doğruluğu ve performansı üzerinde doğrudan belirleyici olup, algoritmanın daha etkili ve verimli çalışmasını sağlar.

- **Model Seçimi (Model Selection):** Bu aşamada, veri setindeki örüntüleri tanımlamak ve anlamlı ilişkileri ortaya çıkarmak için probleme ve veri yapısına en uygun model seçilir. Uygulanacak algoritmanın doğru belirlenmesi, genel başarı oranı üzerinde doğrudan etkilidir.

- **Model Eğitimi (Training):** Seçilen model, hazırlanmış eğitim verileriyle eğitilir ve veriler arasındaki ilişkileri öğrenmesi sağlanır. Bu süreçte modelin, gelecekte doğru tahmin ve genelleme yapabilmesi amaçlanır.

- **Model Değerlendirme (Validation & Testing):** Eğitilen modelin performansı, eğitimden bağımsız doğrulama verileriyle test edilir. Bu aşama, modelin yeni durumlara karşı başarısını ölçer ve düşük performans aşırı öğrenmeye işaret eder. Böyle bir durumda, model parametreleri gözden geçirilmeli veya alternatif bir yapı tercih edilmelidir (Atalay ve Çelik, 2017; Öztürk ve Şahin, 2018; Bou Nassif vd., 2019; Gültepe, 2019; Aylak vd., 2021; Bayrakçı vd., 2021; Gökalp, 2021; Eker vd., 2023).

Makine öğrenmesi günümüzde bankacılık, eğitim, eğlence, pazarlama ve oyun sektörleri başta olmak üzere çok çeşitli alanlarda yaygın bir şekilde kullanılmaktadır. Makine öğrenmesi uygulamaları, kullanılan veri türüne ve öğrenme biçimine göre farklı stratejiler izlemektedir. Temel olarak dört ana strateji çerçevesinde sınıflandırılmaktadır:

- **Denetimli Öğrenme (Supervised Learning):** Makine öğrenmesinde en yaygın kullanılan yöntem olan denetimli öğrenmede, sistem etiketli verilerle eğitilir ve her giriş, ilgili bir çıktı ile eşleştirilir. Model, bu eşleşmeleri öğrenerek benzer verilere doğru tahminler yapmayı hedefler. Çıktı kategorik ise sınıflandırma, sürekli ise regresyon yöntemi kullanılır. E-posta filtreleme, dolandırıcılık tespiti ve hastalık teşhisi gibi alanlarda yaygın olarak uygulanır.

- **Denetimsiz Öğrenme (Unsupervised Learning):** Etiketlenmemiş verilerle çalışan bu yöntemde, sistem verilerdeki desenleri ve benzerlikleri herhangi bir dış yönlendirme olmaksızın kendiliğinden keşfeder. Çoğunlukla kümeleme algoritmaları kullanılır ve büyük veri kümelerinde yapısal örüntülerin bulunmasında etkilidir. YouTube video önerileri ve sosyal medya arkadaş tavsiyeleri gibi uygulamalar bu yönteme örnektir.

- **Pekiştirmeli Öğrenme (Reinforcement Learning):** Bu öğrenme biçiminde sistem, çevresiyle etkileşim kurarak aldığı kararların sonuçlarına göre ödül veya ceza alır ve deneme-yanılma yoluyla en yüksek ödülü getiren eylemleri öğrenir. Özellikle dinamik ve sıralı karar gerektiren ortamlarda etkilidir. Oyun oynayan yapay zekâlar, otonom araçlar ve finansal ticaret stratejileri bu yöntemin başlıca uygulama alanlarıdır.

- **Yarı Denetimli Öğrenme (Semi-Supervised Learning):** Denetimli ve denetimsiz öğrenme tekniklerinin birleşimi olan bu yöntemde, eğitimde hem etiketli hem de etiketlenmemiş veriler kullanılır. Bu sayede, az sayıda etiketli veriyle dahi yüksek doğruluk sağlanabilir. Özellikle veri etiketlemenin maliyetli olduğu durumlarda avantajlıdır. Spam filtreleme, tıbbi görüntü analizi ve duygu analizi gibi alanlarda yaygın olarak uygulanır (Atalay ve Çelik, 2017; Öztürk ve Şahin, 2018; Bou Nassif vd., 2019; Gültepe, 2019; Aylak vd., 2021; Bayrakçı vd., 2021; Gökalp, 2021; Eker vd., 2023). Makine öğrenmesinin kategorileri Şekil 1.5'te gösterilmiştir (Bou Nassif vd., 2019).

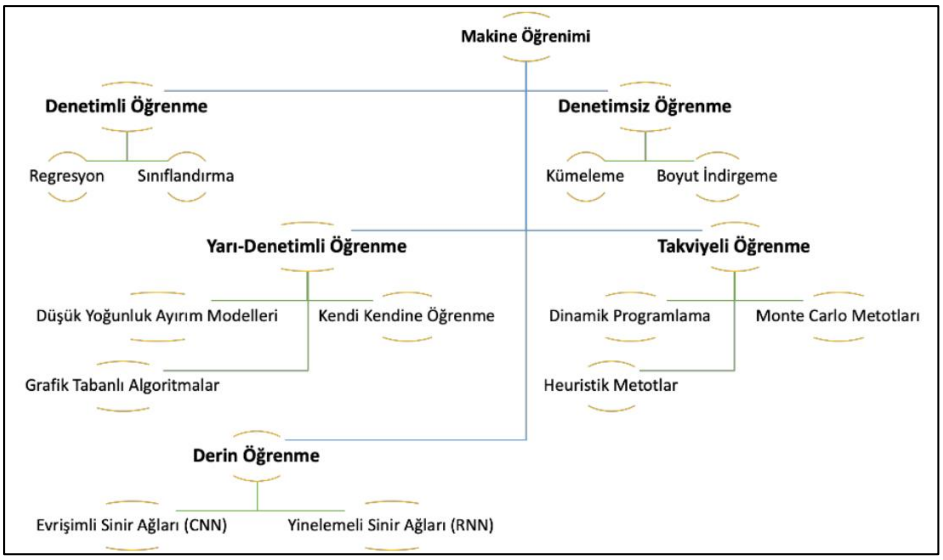

Şekil 1.5. Makine öğrenmesinin kategorileri (Bou Nassif vd., 2019)

1.3. Tezin Amacı

Bu tez çalışmasının temel amacı, çiftçilerin toprak analizine kolay, hızlı ve maliyetsiz şekilde ulaşmasını sağlamak ve veriye dayalı tarımsal karar süreçlerini yaygınlaştırmaktır. Çalışma iki temel aşamadan oluşmaktadır. İlk aşama için RS485 protokolü ile çalışan ve LCD ekranla desteklenen, Arduino tabanlı taşınabilir bir NPK sensör sistemi tasarlanmıştır. Bu sistem, toprakta bulunan azot, fosfor, pH ve potasyum gibi temel besin elementlerini sahada doğrudan ölçebilmektedir. Böylece çiftçi, herhangi bir laboratuvara başvurmadan anında sonuç alabilecektir. Sensör, özellikle kırsal bölgelerde hizmete erişimi kısıtlı üreticiler için önemli bir avantaj sunmaktadır. Bu yönüyle sistem, yerinden veri toplama imkânı sağlayarak dijital tarımın yaygınlaşmasına katkıda bulunmaktadır.

İkinci aşamada, elde edilen bu ölçüm verilerinin işlendiği web tabanlı bir karar destek sistemi geliştirilmiştir. Bu sistem üzerinden çiftçi, bulunduğu ilçeyi ve toprak analiz sonuçlarını (fosfor, potasyum, pH) ilgili alanlara girerek veri akışını başlatmaktadır. Model, bu giriş verilerinden yola çıkarak ilgili toprağın satürasyon, organik madde ve kireç oranlarını tahmin etmektedir. Tahmin edilen bu ikincil değerlerle birlikte Isparta İl Özel İdaresi tarafından sağlanan toprak analiz verileri karşılaştırmalı biçimde işlenmektedir. Bu öneriler, geçmiş tarımsal verimlilikle uyumlu biçimde oluşturulmakta ve çiftçiye açık şekilde raporlanmaktadır. Web arayüzü aracılığıyla

sunulan bu hizmet, kullanıcı dostu yapısı sayesinde her seviyedeki çiftçi tarafından kolaylıkla kullanılabilmektedir.

Bu sistem, sadece veri analizine değil, aynı zamanda sonuçların sade ve anlaşılır şekilde sunulmasına da odaklanmaktadır. Böylece üretici, hangi ürünü hangi toprağa ne zaman ekeceği konusunda bilimsel temellere dayalı karar verebilecektedir. Çiftçinin üretim öncesinde daha bilinçli hareket etmesi hem kaynak kullanımını optimize etmekte hem de tarımsal verimliliği artırmaktadır. Modelin saha uygulamasında kullanılabilirliği, ekonomik erişilebilirliği ve karar destek potansiyeli oldukça yüksektir. Bu bağlamda, geliştirilen sistemin tarımsal sürdürülebilirlik, dijitalleşme ve yerel kalkınma politikaları açısından katkı sağlayacağı öngörülmektedir. Tez kapsamında geliştirilen iki aşamalı bu yapı, düşük maliyetli donanım ve güçlü yazılım bileşenlerini bir araya getirerek bütüncül bir çözüm ortaya koymaktadır. Nihai hedef, veriye dayalı kararlarla üretimi artırmak ve çiftçinin bilimsel bilgiye dayalı, doğru ürünü seçmesini sağlamaktır. Çalışmanın sonuçları, yerel yönetimler, tarım il müdürlükleri ve özel sektör tarafından da entegre sistemlerde kullanılabilir potansiyele sahiptir. Bu bağlamda çalışma, uygulamaya dönük, somut fayda üreten ve geniş ölçekli yaygınlaştırmaya uygun bir yapıya sahiptir.

2. LİTERATÜR

Bu derleme çalışması, tıpta yapay zekâ yöntemlerinin kullanım potansiyelini ve uygulama alanlarını inceleyerek klinik karar destek sistemlerine katkı sunmayı amaçlamaktadır. Yapay zekâ; uzman sistemler, bulanık mantık, genetik algoritmalar ve yapay sinir ağları gibi yöntemlerle klinik tanı, tedavi planlaması ve hasta verilerinin analizi gibi işlevlerde kullanılmaktadır. Tıbbi uzman sistemler, hekimlere karar desteği sağlarken; bulanık mantık, belirsizlik içeren tıbbi verilerin yorumlanmasında etkili çözümler sunmaktadır. Yapay sinir ağları ise görüntü işleme, veri sınıflandırma ve teşhis sistemlerinde başarıyla uygulanmaktadır. Literatür taramasına göre, 1998–2008 yılları arasında bu alanda yapılan yayınlarda özellikle yapay sinir ağları ve bulanık mantık yöntemlerinin öne çıktığı görülmektedir. Örnek uygulamalar arasında, ventilatör yönetimi için geliştirilen FuzzyKBWean sistemi ve akut apandisit tanısı için geliştirilen geri beslemeli yapay sinir ağları modeli yer almaktadır. Her iki sistem de klinik kararlarda doğruluğu artırmış ve hekimlerden önce önerilerde bulunarak zaman kazandırmıştır. Sonuç olarak, yapay zekâ yöntemleri, tıpta karar destek sistemlerinin etkinliğini artırabilecek güçlü araçlardır; ancak gerçek klinik ortamlarda yaygın kullanımı için daha fazla çalışmaya ihtiyaç vardır (Demirhan vd., 2010).

Bu çalışma, geniş tarım alanlarında ölçülmeyen noktalara ait toprak penetrasyon direnç değerlerini tahmin etmek amacıyla üç farklı yapay sinir ağı (YSA) modeli karşılaştırmalı olarak uygulanmıştır. Antalya'da 20 hektarlık bir alandan GPS koordinatları ile birlikte 1 603 noktadan 40 cm derinlikten alınan veriler kullanılmıştır. Kullanılan modeller; Genelleştirilmiş Regresyon Sinir Ağı (GRNN), Çok Katmanlı Algılayıcı (MLP) ve Radyal Tabanlı Fonksiyon (RBF) ağıdır. YSA modellerinin tahmin performansı, ortalama karekök hata (RMSE), ortalama mutlak hata (MAE) ve ortalama hata karesi (MSE) kriterlerine göre değerlendirilmiştir. RBF modeli, özellikle RMSE ve MAE değerleri açısından gerçek değerlere en yakın sonuçları vermiştir. MLP yöntemi, üç model arasında en düşük başarıyı göstermiştir. Elde edilen sonuçlar, geniş üretim alanlarında zaman ve iş gücü tasarrufu sağlamak amacıyla, ölçüm yapılmayan bölgelerde YSA tabanlı tahminleme yöntemlerinin etkin bir şekilde kullanılabileceğini göstermektedir. Çalışma, penetrasyon direncinin mekânsal dağılımını modellemede YSA tekniklerinin pratik ve uygulanabilir çözümler sunduğunu ortaya koymuştur (Ünal vd., 2016).

Bu çalışma, Bangladeş'te tarımsal verimliliği artırmak ve doğru ürün seçimi sağlamak amacıyla derin sinir ağı (DNN) temelli bir tahmin modeli geliştirmeyi hedeflemiştir. Araştırma, 2008–2017 yılları arasında toplanan 0.3 milyonun üzerinde veri noktasını ve 46 farklı çevresel/toprak değişkenini kullanarak; altı temel ürün (Aus, Aman, Boro pirinç türleri, buğday, patates ve jüt) üzerine odaklanmıştır. Modelde üç gizli katmanlı bir DNN kullanılmış; bu yapı destek vektör makineleri (SVM), lojistik regresyon ve rastgele orman algoritmalarıyla karşılaştırılmıştır. DNN modeli, %97.7'ye ulaşan doğruluğu ve %2.3'lük hata oranıyla en iyi performansı göstermiştir. Veriler; toprak türü, nem, yapı, gübre kullanımı, sıcaklık, yağış ve nem gibi değişkenlerle genişletilmiş; ayrıca her bölge için özel analizler yapılmıştır. Tangail bölgesi, yüksek nem ve toprak verimliliği nedeniyle jüt üretiminde en verimli bölge olarak saptanmıştır. Verilerin manuel olarak dijitalleştirilmesi ve temizlenmesi süreci, modelin güvenilirliğini artıran önemli bir adımdır. Sonuçlar, makine öğrenmesinin geleneksel tarım yöntemlerinin yerini alabilecek güçlü bir araç olduğunu ve bölgesel karar destek sistemlerinde etkin biçimde kullanılabileceğini ortaya koymuştur (Islam vd., 2018).

Bu çalışma, makine öğrenmesi algoritmaları kullanarak hem mahsul veriminin tahminini yapmak hem de her bir mahsul için uygun gübre önerisinde bulunmak amacıyla gerçekleştirilmiştir. Çalışmada, son beş yıla ait mahsul verim kayıtları, toprak besin değerleri ve konum bilgileri birleştirilerek, destek vektör makineleri (SVM) ve rastgele orman (RF) algoritmaları uygulanmıştır. Sistem; toprak sınıflandırması, ürün verimi tahmini ve gübre önerisi olmak üzere üç aşamadan oluşmaktadır. Toprak sınıflandırmasında RF algoritması %86.35 doğrulukla daha iyi performans gösterirken; ürün verimi tahmininde SVM algoritması %99.47 ile daha başarılı sonuç vermiştir. Her algoritma için doğruluk, geri çağırma, F1 skoru ve hata oranları grafiklerle desteklenerek sunulmuştur. Sistem, ürün tahminiyle birlikte hava durumu, sıcaklık, nem ve atmosfer basıncı gibi çevresel bilgileri de entegre şekilde sunmaktadır. Mahsule özel olarak önerilen gübre tipi, kullanıcıya grafiksel arayüz üzerinden sunulmaktadır. Deneysel çalışmalar Python programlama dili ile gerçekleştirilmiş ve farklı kaynaklardan toplanan tarımsal veri setleri kullanılmıştır. Araştırma, çiftçilere bölgesel koşullara göre doğru ürün ve gübre tercihi yapma olanağı sağlayarak, tarımsal verimliliği artırma potansiyeline sahiptir. Çalışmanın ilerleyen

aşamalarında, mobil uygulama entegrasyonu ve görüntü işleme temelli hastalık tanıma sistemi planlanmaktadır (Bondre ve Mahagaonkar, 2019).

Bu çalışma, Türkiye'nin Kastamonu ilinde görülen hava kirliliğini öngörebilmek amacıyla, meteorolojik parametrelere dayalı olarak çeşitli makine öğrenmesi algoritmalarının tahmin performanslarını karşılaştırmak üzere gerçekleştirilmiştir. Çalışmada kullanılan veri seti, 2015–2018 yılları arasında ölçülen PM10, SO2, hava sıcaklığı, basınç, nem, rüzgâr yönü ve hızı gibi değişkenlerden oluşmaktadır. Veriler Min-Max normalizasyon yöntemiyle ön işleme tabi tutulmuş ve %70 eğitim, %30 test olarak ayrılmıştır. Tahmin modellerinde; Yapay Sinir Ağları (YSA), Rastgele Orman (Random Forest), Karar Ağacı, K-En Yakın Komşu, Lojistik Regresyon, Lineer Regresyon ve Basit Bayes yöntemleri uygulanmıştır. En yüksek tahmin doğruluğu %99 oranıyla Random Forest ve Karar Ağacı modellerinde elde edilirken, YSA modeli %87 ve Lineer Regresyon yalnızca %30 doğruluk sağlamıştır. Modeller; R^2, MSE, RMSE ve MAE gibi performans metrikleriyle değerlendirilmiştir. Sonuçlar, hava kirliliği tahmini gibi çevresel problemlerde klasik yöntemlere kıyasla makine öğrenmesi tekniklerinin daha başarılı ve güvenilir olduğunu göstermektedir. Çalışma, hava kirliliğiyle mücadelede erken uyarı sistemlerinin geliştirilmesine katkı sağlayabilecek bir yöntem önerisi sunmaktadır. Ayrıca literatürdeki benzer çalışmalarla karşılaştırmalı performans analizleri sunularak yöntemin geçerliliği güçlendirilmiştir (Gültepe, 2019).

Bu çalışma, çiftçilerin hava durumu, toprak yapısı ve bitki besin değerlerine göre en uygun tarım ürününü seçebilmesine yardımcı olacak bir öneri sistemi geliştirmeyi hedeflemiştir. Araştırmada, PART, JRip ve Decision Table gibi kural tabanlı makine öğrenmesi algoritmaları kullanılmış ve performansları doğruluk, kesinlik, hatırlama oranı ve F-ölçütü gibi kriterlerle karşılaştırılmıştır. Veri seti, Hindistan Gıda ve Tarım Odası tarafından sağlanmış ve Kaggle havuzundan elde edilen 2 200 gözlemden oluşmuştur. Modelin eğitimi WEKA aracı ile gerçekleştirilmiş, %60 eğitim–%40 test bölünmesi uygulanmıştır. PART algoritması %98.33 doğrulukla en yüksek başarıyı gösterirken, model kurma süresinde de en hızlı sonuçları vermiştir. Bu algoritma, C4.5 ve RIPPER tabanlıdır ve karar ağacını tamamen oluşturmadan kısmi yapılarla tahminlerde bulunur. JRip algoritması %95.9, Decision Table ise %87.42 doğruluk oranına ulaşmıştır. Yapılan deneylerde, PART algoritmasının aynı zamanda en düşük

hata oranına ve en yüksek F1 skoruna sahip olduğu saptanmıştır. Bu sistem, özellikle tarımsal kaynakların doğru kullanımı, ürün çeşitliliği ve verimliliğin artırılması açısından çiftçilere karar destek sistemi olarak katkı sağlamaktadır (Parameswari vd., 2021).

Bu çalışma, Hindistan'daki çiftçilerin ürün seçimi, gübre tavsiyesi ve bitki hastalıklarının erken teşhisi gibi temel tarımsal sorunlarını çözmeye yönelik açık kaynaklı, kullanıcı dostu bir web uygulaması geliştirmeyi amaçlamaktadır. Uygulama üç temel bileşenden oluşmaktadır: Rastgele Orman (Random Forest) algoritmasıyla çalışan ürün öneri sistemi, kural tabanlı gübre öneri modülü ve EfficientNet mimarisiyle eğitilmiş bir yapay sinir ağına dayanan yaprak görüntüsü üzerinden bitki hastalığı tespit sistemidir. Hastalık tespit modelinin yorumlanabilirliği LIME (Local Interpretable Model-agnostic Explanations) yöntemi ile desteklenmiş ve kullanıcıya modelin hangi görüntü bölgelerine odaklandığı gösterilmiştir. Ürün önerisi modeli, 2 200 örnek içeren ve 22 mahsul sınıfını kapsayan Kaggle veri setiyle eğitilmiş; en yüksek doğruluk oranı %99.5 ile Random Forest çalışmakta olup, en etkili faktörlerin sırasıyla yağış, nem ve potasyum olduğu belirlenmiştir. Hastalık tespiti için kullanılan PlantVillage veri seti 87 000 görüntüden oluşmakta ve EfficientNet modeli %99.8 doğrulukla en iyi performansı göstermektedir. Gübre önerisi ise, NPK değerlerindeki eksiklik ya da fazlalığa göre altı farklı öneri sunan basit bir IF-THEN kural sistemiyle yapılmaktadır. Sistem ayrıca tarıma dair haberleri toplayarak çiftçiye güncel bilgi akışı sağlamakta ve detaylı hastalık portalıyla hastalıkların özelliklerini ve çözüm yollarını sunmaktadır. Çalışma hem makine öğrenmesi hem de derin öğrenmeyi aynı platformda bütüncül şekilde sunarak dijital tarım teknolojilerinde bütünleşik çözüm örneği sunmaktadır. Bu bütünleşik yapay zekâ destekli sistem, düşük altyapıya sahip bölgelerde bile tarımsal karar süreçlerini iyileştirme potansiyeline sahiptir (Gupta vd., 2022).

Bu derleme çalışması, son on yılda geliştirilen makine öğrenmesi tabanlı besin yönetimi ve gübre öneri sistemlerini inceleyerek, tarımsal üretimde verimliliği artırma ve çevresel etkileri azaltma potansiyelini değerlendirmektedir. Çalışmada, özellikle azot ve NPK yönetimi üzerine odaklanan pek çok model analiz edilerek, kullanılan makine öğrenmesi algoritmaları (Random Forest, Destek Vektör Makineleri, Yapay Sinir Ağları ve Derin Öğrenme vb.), öznitelik seçimi yöntemleri ve performans

metrikleri detaylı biçimde ele alınmıştır. Tarımsal sensör verileri, görüntüleme sistemleri ve hava koşulları gibi çok kaynaklı verilerin entegrasyonuyla oluşturulan modellerin, doğruluk ve karar destek gücü açısından yüksek başarı gösterdiği vurgulanmıştır. Derlemede, görüntü tabanlı sistemlerin özellikle azot yönetiminde öne çıktığı; Random Forest algoritmasının hem azot hem de NPK bazlı tahminlerde en çok tercih edilen ve başarılı model olduğu belirtilmiştir. Ayrıca eksik veriler, çok boyutluluk ve standart veri seti eksikliği gibi uygulama zorluklarına dikkat çekilmiştir. Derin öğrenme algoritmaları sayesinde görüntü verileri üzerinden otomatik öznitelik çıkarımı yapılabilmekte ve bu durum model performansını artırmaktadır. Ancak yetersiz veri kalitesi ve temsiliyet eksikliği, model genellemesinin önünde hâlâ önemli bir engel olarak durmaktadır. Yazarlar, veriye dayalı tarım karar sistemlerinin yaygınlaştırılması için açık veri paylaşımı ve metodolojik standardizasyonun şart olduğunu belirtmektedir (Ennaji vd., 2023).

Bu çalışma, gelişmekte olan ülkelerde artan gıda ihtiyacına çözüm olarak, çevresel ve tarımsal geçmiş verilerine dayalı olarak uygun tarım ürünlerini öneren bir makine öğrenmesi sistemi geliştirmeyi amaçlamaktadır. Bangladeş örneği üzerinden yürütülen model çalışmada; 1969–2021 yılları arasındaki iklimsel ve tarımsal verilerden oluşan 7000 örneklik bir veri kümesi üzerinde eğitilmiş; yağış, sıcaklık, rüzgâr, nem gibi sekiz temel çevresel değişken dikkate alınmıştır. Araştırmacılar, KNN, Random Forest ve Ridge Regression algoritmalarını birleştirerek "KRR" adlı özgün bir model tasarlamıştır. Model, beş temel ürün (Aus, Aman, Boro pirinç türleri, buğday ve patates) için yüksek doğrulukla tahminlerde bulunmuş; R^2 değeri %99'a ulaşmıştır. Çalışma ayrıca önerilen KRR modelinin SVR, Naive Bayes, CatBoost gibi klasik ve ensemble modellere göre anlamlı şekilde üstün olduğunu Diebold–Mariano testi ile göstermiştir. Sistemin son aşamasında, tahmin edilen üretim miktarına göre bir ürün öneri sistemi kurulmuş ve hangi bölgede hangi ürünün ekilmesinin daha verimli olacağı belirtilmiştir. KRR modeli, belirsiz çevresel koşullarda dahi stabil sonuçlar vermesi sayesinde çiftçilere güvenilir karar desteği sunmaktadır. Gelecek çalışmalarda mobil uygulamalar aracılığıyla çiftçilerin doğrudan erişebileceği bir sistemin oluşturulması hedeflenmektedir (Hasan vd., 2023).

Bu çalışma, gübre uygulama zamanlamalarının optimize edilmesine yönelik, büyük ölçekli ve heterojen verilerle çalışan bir makine öğrenmesi modeli geliştirmeyi

amaçlamaktadır. Özellikle azotlu gübrelerin doğru zamanda ve doğru miktarda uygulanmaması hem ekonomik kayıplara hem de çevresel zararlara yol açmaktadır. Çalışmada önerilen iki aşamalı sistem, ilk olarak gerekli azot uygulama sayısını, ardından bu uygulamaların hangi günlerde ve hangi miktarlarda yapılması gerektiğini tahmin etmektedir. Modelde Random Forest algoritması kullanılmış, sonuçlar ise çok değişkenli regresyon ağaçları ve çapraz doğrulama yöntemiyle değerlendirilmiştir. Uygulama, kışlık buğday örneği üzerinden yürütülmüş ve her bir besin için özgün zaman çizelgeleri çıkarılmıştır. Veriler yüksek boyutlu ve eksik değer içerse de özel ön işleme yöntemleriyle model başarıyla çalıştırılmıştır. Nitrat, magnezyum ve sülfür gibi elementlerde yüksek doğruluk oranları elde edilirken, bazı mikro besinler için veri yetersizliğinden dolayı modelin başarısı düşmüştür. Sonuçlar, tarımsal verimliliğin artırılmasında veri odaklı gübre zamanlamasının önemini göstermektedir. Bu yaklaşım, özellikle orta ve büyük ölçekli çiftliklere gübreleme sürecinde zaman ve kaynak tasarrufu sağlarken sürdürülebilir tarıma da katkı sunmaktadır (Ikhlaq ve Kechadi, 2023).

Tarım gelişmekte olan ülkelerin ekonomisi için vazgeçilmez bir unsurdur. Bu çalışmada tarım sektörünün daha ileri bir noktaya taşınması hedeflenmiştir. Çalışma, çiftçilere araziye uygun ürün ve gübre önerileri sunan, makine öğrenmesine dayalı çok kriterli bir tarımsal karar destek sistemi olan AgriRec algoritmasını önermektedir. Sistem, toprak özellikleri, su düzeyi, arazi büyüklüğü ve ürünlerin piyasa değeri gibi çeşitli parametreleri dikkate alarak hem ürün hem de gübre önerileri sunmaktadır. Araştırma, Hindistan'ın Gujarat bölgesinden elde edilen 5 000 arazi örneği ve 24 farklı ürün ile gerçekleştirilmiştir. AgriRec iki aşamadan oluşmaktadır: ürün öneri sistemi (CRS) ve gübre öneri sistemi (FRS). Veriler, Hindistan hükümetinin resmi tarım veri portallarından alınmıştır. Sistem, ürün önerilerinde %95.85, gübre önerilerinde ise %92.11 doğruluk oranına ulaşmıştır. Ayrıca, geleneksel yöntemlere kıyasla 4 kat daha hızlı çalıştığı belirtilmiştir. AgriRec'in gelecekte hastalık ve zararlı tanıma modülleriyle genişletilmesi planlanmaktadır (Patel ve Patel, 2023).

Bu çalışma, Ruanda'da tarım uygulamalarını dönüştürmeyi hedefleyen bir ürün ve gübre öneri sistemi geliştirmektedir. Araştırmanın temel amacı, toprak verileri ve yapay zekâ destekli analizlerle çiftçilere hangi ürünleri yetiştirmeleri ve hangi gübreleri kullanmaları gerektiğine dair özelleştirilmiş öneriler sunmaktır. Sistem, bir

yapay sinir ağı modeliyle çalışan ürün öneri modülü ve kural tabanlı bir gübre öneri sistemi olmak üzere iki temel bileşenden oluşmaktadır. Veri seti, Ruanda'da yaygın olarak yetiştirilen mahsullerin azot, fosfor, potasyum ve pH düzeylerine göre derlenmiştir. Topraktan gerçek zamanlı veri toplamak amacıyla IoT tabanlı sensörler kullanılmıştır. Ürün öneri modelinin doğruluğu %97 olarak raporlanmış, sistem farklı ürün türlerine göre yüksek hassasiyet göstermiştir. Gübre öneri sistemi, toprak pH'ına ve ürün ihtiyaçlarına göre mantıksal kurallar çerçevesinde kişiselleştirilmiş öneriler sunmaktadır. Sistem, çiftçilere sadece hangi ürünü değil, aynı zamanda mevcut toprak koşullarına göre hangi gübreyi hangi miktarda kullanmaları gerektiğini de belirtmektedir. Araştırmada sistemin gerçek zamanlı uygulanabilirliği test edilmiş ve öneri sisteminin bulut tabanlı entegrasyonu için kavramsal bir mimari de sunulmuştur. Çalışma, düşük üretkenliğe sahip tarım alanlarında sürdürülebilirliği ve verimliliği artırmak adına yapay zekâ ve IoT'nin birlikte nasıl etkin kullanılabileceğini göstermektedir (Musanase vd., 2023).

Bu çalışma, tarımsal verimliliği artırmak amacıyla, toprak ve çevresel verilere göre en uygun gübre türünü önerebilen bir makine öğrenmesi tabanlı karar destek sistemi geliştirmeyi hedeflemiştir. Toprak rengi, pH değeri, yağış miktarı, sıcaklık ve ekili ürün gibi değişkenlerden yararlanılarak oluşturulan model; Destek vektör makinaları (SVM), Yapay sinir ağları (ANN) ve XGBoost algoritmaları ile eğitilmiştir. Çalışmada Python dili ve Flask kullanılarak kullanıcı dostu bir web arayüzü tasarlanmıştır. Veri seti, tarım ürünleri ve gübreleme bilgilerinden oluşmakta olup ön işleme ve standartlaştırma adımlarından geçirilmiştir. ANN modeli %87.45 doğrulukla başarılı sonuç verirken, XGBoost modeli %87.46 ile en yüksek doğruluğa ulaşmıştır; SVM modeli ise %37.9 gibi düşük bir performans göstermiştir. Model değerlendirmesinde doğruluk, kesinlik, F1 skoru ve doğrulama kayıpları dikkate alınmıştır. Uygulama süreci veri toplama, ön işleme, model eğitimi ve kullanıcı tahmin modülü olmak üzere çok katmanlı bir mimariyle yapılandırılmıştır. Çalışma, çiftçilerin temel çevresel verileri girerek kendilerine uygun gübre türünü kolayca öğrenmesini sağlamaktadır. Sonuç olarak bu sistem, sürdürülebilir tarım uygulamalarına katkı sunarak, doğru gübreleme kararlarıyla verimi artırma potansiyeli taşımaktadır (Bommireddy, 2024).

Bu çalışma, süs bitkiciliği özelinde dikey tarım uygulamaları için çevre kontrollü bir karar destek sistemi geliştirmeyi hedeflemiştir. Örnek bitki olarak seçilen hibrit Afrika

menekşesi, iklim kontrollü ortamda yıl boyunca üretime alınmış; bitkilerin canlılık ve gelişim performansları sensör verileri ve görüntü işleme teknikleriyle takip edilmiştir. Çalışmada; bitki yetiştirme altyapısı, bilişim sistemi, yapay zekâ destekli karar mekanizmaları ve görüntü analiz süreçleri entegre bir sistemde birleştirilmiştir. YOLOv8 mimarisi kullanılarak çeşitli yaprak sayısı, çiçek sayısı ve alan ölçümleri analiz edilmiştir. Besin dozlarına göre farklı bitki tepkileri izlenerek kök çürüklüğü, erken çiçeklenme ve gelişim eksikliği gibi semptomlar karar destek sistemi aracılığıyla belirlenmiştir. Geliştirilen sistem, uzman görüşü ile birleştirilmiş görsel veriler sayesinde üreticilere hızlı, doğru ve öngörülebilir kararlar alma imkânı sunmaktadır. Tez, süs bitkilerinde üretim verimliliğini artıracak şekilde çevre kontrollü tarım uygulamalarının potansiyelini göstermektedir. Sistem ayrıca bitki türlerine özel veri tabanları oluşturarak, gelecekteki üretim faaliyetlerine rehberlik edecek nitelikte referans bilgiler sağlamaktadır. Çalışma, dikey tarım alanında karar destek sistemlerinin süs bitkisi üretimindeki potansiyelini göstererek sektöre önemli bir katkı sunmaktadır (Çökren, 2024).

Bu çalışma, Hindistan'da farklı bölgelerde yetiştirilen tarımsal ve bahçecilik ürünleri için, azot, fosfor, potasyum ve Ph gibi toprak besin değerlerinin yanında sıcaklık, yağış, nem gibi iklim özelliklerine dayalı ürün önerisinde bulunmak amacıyla gerçekleştirilmiştir. Kaggle veri havuzundan alınan 2 100 gözlemden oluşan veri kümesi, 11 tarım ürünü ve 10 bahçecilik ürünü içermektedir. Araştırmada destek vektör makineleri, karar ağaçları, rastgele orman, K-en yakın komşu ve XGBoost olmak üzere beş farklı makine öğrenmesi modeli eğitilmiş ve karşılaştırılmıştır. Tarım ve bahçecilik verileri tarım ürünleri, bahçecilik ürünler ve her ikisinin birleşimi olmak üzere üç farklı modelleme grubunda analiz edilmiştir. XGBoost modeli tüm gruplarda en yüksek doğruluk oranına ulaşmış; tarım ürünleri için %99.09, bahçecilik ürünleri için %99.3 ve birleşik veri seti için %98.51 doğruluk sağlamıştır. Verilerin ayrı kategorilerde analiz edilmesinin, karışık modellere göre daha isabetli sonuçlar verdiği saptanmıştır. Elde edilen bulgular, bölgeye özel doğru ürün önerileri yapılabilmesi için makine öğrenmesi destekli karar sistemlerinin etkili bir araç olduğunu ortaya koymaktadır. Bu yaklaşım, kullanıcı dostu bir yapay zekâ arayüzü aracılığıyla çiftçilere verimli gübreleme ve ürün seçimi konusunda yol gösterici olabilir (Dey vd., 2024).

Bu çalışma, çiftçilerin tarımsal kararlarını daha isabetli verebilmesi amacıyla, çevresel ve toprak verilerine dayalı olarak en uygun ürünü öneren makine öğrenmesi tabanlı bir sistem geliştirmeyi amaçlamaktadır. Model, hava durumu, sıcaklık, nem, pH, yağış ve NPK gibi değişkenleri içeren veri setiyle eğitilmiş ve Gaussian Naïve Bayes (GNB), Karar Ağaçları (DT), Lojistik Regresyon (LR), Destek Vektör Makineleri (SVM) ve Rastgele Orman (RF) algoritmaları karşılaştırılmıştır. GNB algoritması %99 doğrulukla en başarılı model olarak öne çıkmıştır. Modelin kurulumu; veri temizleme, öznitelik seçimi, eğitim-test ayrımı, model eğitimi, doğrulama ve kullanıcı dostu arayüz entegrasyonuyla çok aşamalı olarak yürütülmüştür. Streamlit ile geliştirilen grafik arayüz sayesinde sistem, çiftçiler tarafından kolaylıkla kullanılabilir hâle getirilmiştir. Modelin performansı doğruluk, kesinlik, hatırlama oranı ve F1 skoru gibi metriklerle değerlendirilmiş; ROC eğrisi ve kutu grafikleriyle kararlılığı görselleştirilmiştir. Çalışma, geleneksel yöntemlere kıyasla %20 oranında daha yüksek ürün verimi sağladığını ileri sürmektedir. Bu sistem, toprakta fosfor ve kalsiyum fazlalığından kaynaklı fitotoksisite riskini azaltmada da etkili bulunmuştur (Kiran vd., 2024).

Bu çalışma, makine öğrenmesi algoritmalarının, yerel düzeyde ekonomik olarak en uygun gübre uygulama oranlarını (EOIR) doğru bir şekilde tahmin edip edemeyeceğini sorgulamak amacıyla yapılmıştır. Japonya'da kışlık buğday üretimi üzerine yürütülen bir arazi deneyi ile, farklı gübreleme oranlarının verim üzerindeki etkisi değerlendirilmiş ve 970 gözlemden oluşan veri seti kullanılmıştır. Uygulanan modellemelerde dört farklı algoritma (RF, XGBoost, SVR, ANN) kullanılmış ve sekiz toprak özelliğinin 255 farklı kombinasyonu denenmiştir. Elde edilen sonuçlar, EOIR tahminlerinin ve bu tahminlere dayalı kazançların algoritma ve değişken seçimine son derece duyarlı olduğunu göstermiştir. EOIR değerlerindeki varyasyon katsayıları bazal gübreleme için %13.3–31.5, üst gübreleme için ise %14.2–30.5 arasında değiştiği raporlanmıştır. Bazı modeller (özellikle ANN) daha yüksek belirsizlik ve daha düşük tahmini kazanç üretmiştir. Bu durum, yüksek doğrulukla verim tahmini yapan modellerin bile her zaman doğru gübre önerileri sunamayabileceğini ortaya koymaktadır. Araştırma, model belirsizliklerinin, makine öğrenmesi tabanlı gübre tavsiyelerinin güvenilirliği üzerinde kritik bir etkisi olduğunu vurgulamaktadır. Bu nedenle, bu tür karar destek sistemlerinin geliştirilmesinde hem algoritma seçimi hem

de tarımsal bilgi ile desteklenen bütüncül yaklaşımlar önerilmektedir (Tanaka vd., 2024).

Bu çalışma, iklim değişikliği, tarım arazilerinin azalması ve artan gıda talebi gibi küresel sorunlara çözüm olarak, bölgesel tarımsal çeşitliliği artırmayı hedefleyen açıklanabilir bir ürün öneri sistemi geliştirmeyi amaçlamıştır. Geliştirilen AgroXAI sistemi, IoT tabanlı sensörlerle toplanan iklim ve toprak verilerini işleyerek, yapay zekâ destekli kararlar üretmekte ve bu kararları kullanıcıya açıklanabilir biçimde sunmaktadır. Modelin temelini KNN, Random Forest, Decision Tree, SVM, LightGBM ve Multilayer Perceptron algoritmaları oluştururken; SHAP, LIME, ELI5 ve Counterfactual yöntemleri ile kararların yorumlanabilirliği sağlanmıştır. Random Forest modeli %99'un üzerinde doğruluk oranı ile en başarılı performansı göstermiştir. SHAP ve LIME gibi yöntemlerle, hangi çevresel faktörlerin ürün tercihini etkilediği ayrıntılı biçimde açıklanmıştır. Counterfactual analiz yöntemiyle mevcut koşullarda ekilebilecek alternatif ürünler de kullanıcıya önerilmiştir. Bu sayede sistem, yalnızca mevcut öneriyi değil, çevresel koşullar değiştirildiğinde nelerin yetiştirilebileceğini de göstermektedir. AgroXAI, yalnızca yüksek doğrulukla çalışmakla kalmayıp, aynı zamanda kararlarını anlaşılır kılarak çiftçilerin güvenle kullanabileceği akıllı bir destek sistemi sunmaktadır (Turgut vd., 2024).

Bu çalışma, toprak besin değerleri ve çevresel parametreleri dikkate alarak 22 farklı tarım ürününe yönelik en uygun ürün önerisini sunan bir makine öğrenmesi modeli geliştirmeyi amaçlamaktadır. Önerilen sistem, Random Forest (RF) ve XGBoost (XGB) algoritmalarının entegrasyonu ile oluşturulan yeni bir topluluk modeli olan RFXG üzerine kuruludur. Veri kümesi, Pakistan'a ait gerçek zamanlı iklim ve toprak ölçümlerini içermekte; azot, fosfor, potasyum, sıcaklık, nem, pH ve yağış gibi yedi temel özelliği kapsamaktadır. Modelin eğitimi ve testi için 2 200 örnekten oluşan veri seti %80 eğitim, %20 test oranıyla ayrılmıştır. Ek olarak, veri ön işleme, keşifsel veri analizi, korelasyon incelemesi ve hiperparametre ayarı gibi adımlar detaylı biçimde uygulanmıştır. RFXG modeli %98 doğruluk, kesinlik, geri çağırma ve F1 skoru ile diğer tüm tekil modelleri geride bırakmıştır. Özellikle RF'in yüksek boyutlu veriyle başa çıkma yetisi ve XGB'nin öğrenme gücü bu başarıda belirleyici olmuştur. Sınıf bazlı değerlendirmelerde en düşük başarı papaya ürününde %90 iken, diğer ürünlerde doğruluk daha yüksektir. Araştırma, tarımsal verimliliği artırmak ve çiftçilerin doğru

ürün seçimini kolaylaştırmak amacıyla uygulanabilir ve esnek bir sistem sunmaktadır. Gelecekte bu modelin derin öğrenme tabanlı sistemlerle birleştirilmesi planlanmakta olup, hassas tarım uygulamalarında yaygın kullanımı hedeflenmektedir (Afzal vd., 2025).

Bu çalışma, tarımsal verimliliği artırmak ve sürdürülebilir üretimi desteklemek amacıyla bulut tabanlı ve SMS uyarı sistemine sahip yenilikçi bir Ürün Tavsiye Modeli (TCRM) geliştirmeyi hedeflemiştir. Model; azot, fosfor, potasyum, sıcaklık, nem, pH ve yağış gibi çevresel ve toprak parametrelerine dayalı olarak ürün önerileri sunmakta, aynı zamanda karar vericilere gerçek zamanlı veriyle desteklenmiş SMS bildirimleri göndermektedir. Makine öğrenmesi algoritmaları (Random Forest, KNN, Lojistik Regresyon, AdaBoost) ile karşılaştırmalı olarak değerlendirilen TCRM, %94 doğruluk, %94.46 kesinlik ve %97.67 çapraz doğrulama başarısıyla üstün performans göstermiştir. Modelin mimarisi, karar ağaçları ve çok başlıklı dikkat mekanizmaları içeren derin öğrenme katmanlarıyla zenginleştirilmiş ve TensorFlow ile uygulanmıştır. Ürün tavsiye modelinin sunduğu öneriler, yalnızca ürün seçimiyle sınırlı kalmayıp gübre tavsiyesi gibi tamamlayıcı kararları da kapsamaktadır. Kullanıcı arayüzü AWS altyapısıyla bulutta barındırılmakta ve düşük kaynaklı bölgelerde de kolay erişim sağlamaktadır. Bu sistem, tarımsal girdilerin etkin kullanımını sağlayarak çevresel etkiyi azaltmakta ve küçük çiftçilerin de veri temelli karar süreçlerine katılımını teşvik etmektedir. Araştırma, bölgeye özgü modellerle genişletildiğinde, farklı tarım alanlarında ölçeklenebilir ve uyarlanabilir çözümler sunma potansiyeline sahiptir (Singh ve Sharma, 2025).

Yapılan literatür incelemeleri sonucu, makine öğrenmesi destekli ürün ve gübre öneri sistemlerinin genellikle hazır veri setleriyle çalıştığını, sahadan veri toplama süreçlerinin göz ardı edildiğini göstermektedir. Bu bağlamda, 20 adet akademik çalışmanın ortak noktasının; sistemlerin büyük ölçüde varsayımsal ya da sabit veri kümeleri üzerine kurgulanması olduğu söylenebilir. Oysa bu tez çalışması, hem gerçek saha verisi toplayabilen donanım temelli bir sensör sistemi hem de bu verileri doğrudan işleyebilen bir yazılım mimarisi sunarak literatürdeki önemli bir boşluğu doldurmaktadır. Ayrıca geliştirilen sistem, çiftçinin bizzat kullandığı veriler üzerinden sonuç vermekte ve model çıktıları gerçek saha değerleriyle doğrulanarak önerilerin güvenilirliğini artırmaktadır. Sensör-haberleşme-yapay zekâ üçlüsünü bir araya

getiren bütünleşik yapısı sayesinde çalışma hem mühendislik hem de tarım bilimleri alanlarında disiplinlerarası bir katkı sunmaktadır. Bu yönüyle tez, yalnızca akademik bilgi üretimiyle sınırlı kalmayıp sahaya uygulanabilir nitelikte, ölçeklenebilir bir çözüm ortaya koymaktadır.

3. MATERYAL VE YÖNTEM

Gerçekleştirilen tez çalışmasında, azot (N), fosfor (P) ve potasyum (K) değerlerini ölçebilen NPK sensörünün, çiftçilere gerçek zamanlı veri sunması amaçlanmıştır. Bu doğrultuda, sensör ağı kullanıcı deneyimini gözeten bir anlayışla tasarlanmış; taşınabilir yapısı sayesinde farklı tarım arazilerinde kolaylıkla kullanılabilecek şekilde yapılandırılmıştır. Böylece, çiftçilerin toprak yapısına ilişkin daha sağlıklı veriler elde etmeleri ve bu doğrultuda tarımsal kararlarını daha bilinçli biçimde almaları hedeflenmiştir. Sonuç olarak, geliştirilen bu sistem; taşınabilir, hızlı, kullanıcı odaklı ve veri temelli bir toprak analiz aracı olarak, modern tarım uygulamalarına önemli katkılar sunma potansiyeli taşımaktadır.

3.1. Materyal

3.1.1. NPK sensörü

Günümüzde hassas tarım uygulamalarının yaygınlaşmasıyla birlikte, toprak besin elementlerinin doğru ve hızlı şekilde ölçülmesini sağlayan sensör teknolojileri, modern tarımın vazgeçilmez bileşenlerinden biri hâline gelmiştir. Bu doğrultuda geliştirilen NPK sensörleri, toprakta bulunan azot (N), fosfor (P) ve potasyum (K) gibi bitki gelişimi için hayati öneme sahip makro besin elementlerini anlık olarak tespit edebilmektedir. Bitki büyüme döngüsünün çeşitli evrelerinde bu elementlerin eksik ya da fazla olması, doğrudan ürün verimliliği, kalite ve hastalık direnci üzerinde belirleyici rol oynamaktadır. Bu nedenle, NPK sensörleri tarafından sağlanan veriler; gübreleme zamanlaması, gübre türü ve miktarının belirlenmesi, sulama programlarının optimize edilmesi gibi pek çok tarımsal kararda karar destek aracı olarak değerlendirilmektedir. Ölçüm sonuçlarının nicel verilere dönüştürülmesi, üreticilere daha öngörülebilir ve sürdürülebilir tarımsal stratejiler geliştirme olanağı tanımaktadır. Böylece, NPK sensörlerinin kullanımı yalnızca bitki sağlığını izlemekle sınırlı kalmayıp, aynı zamanda tarımsal üretim süreçlerinin bütüncül bir biçimde yönetilmesine katkı sağlamaktadır (Altıntaş, 2025).

3.1.1.1. NPK sensörlerinin uygulama alanları

NPK sensörleri, yalnızca toprak besin düzeylerini ölçmekle kalmayıp, farklı disiplinlerdeki uygulamalarıyla da modern tarımın önemli bileşenlerinden biri hâline gelmiştir.

- **Tarım ve Bahçecilik:** NPK sensörleri, topraktaki azot, fosfor ve potasyum seviyelerini hızlı ve doğru şekilde tespit ederek, çiftçilere bilimsel verilere dayalı gübreleme stratejileri geliştirme olanağı sunar. Bu teknoloji, gereksiz gübre kullanımını önleyip bitki gelişimini optimize ederken, üretim maliyetlerini düşürür ve çevresel etkileri azaltır. Uzun vadede ise ürün kalitesinin artmasına katkı sağlar.

- **Su Kaynakları Yönetimi:** NPK sensörlerinden elde edilen veriler, sürdürülebilir su kullanımı için kritik öneme sahiptir. Hassas gübreleme ile gereksiz gübre kullanımının önüne geçilerek azot ve fosforun yer altı sularına karışma riski azalır, böylece su kirliliği önlenir. Ayrıca, sensör destekli tarımsal planlama ile sulama programları optimize edilerek su tasarrufu sağlanır.

- **Biyoteknoloji ve Çevre Bilimleri:** NPK sensörleri, toprak, su ve çevresel faktörlerdeki değişimleri izlemek için kullanılır. Gerçek zamanlı veriler, araştırmacıların toprak sağlığı, mikrobiyal faaliyetler ve biyolojik çeşitlilik gibi alanlarda daha hassas değerlendirmeler yapmasını sağlar. Böylece NPK sensörleri, çevresel sürdürülebilirlik ve bilimsel araştırmalar için de değerli bir araçtır (Altıntaş, 2025).

3.1.1.2. NPK sensörlerinin avantajları

- **Hızlı ve Kesin Sonuçlar:** NPK sensörleri, topraktaki besin maddelerini anlık olarak sahada tespit edebilir. Böylece laboratuvara ihtiyaç duymadan hızlı ve zaman kaybı olmadan ölçüm yapılır. Sahada gerçekleştirilen bu ölçümler, yüksek doğrulukla kesin veriler sunar.

- **Verimli Gübreleme:** Topraktaki makro besin elementlerinin doğru tespiti, gübreleme süreçlerinin optimize edilmesini sağlar. Böylece çiftçiler, yalnızca gerekli element ve miktarlarda gübre kullanarak maliyetleri düşürür ve tarımsal verimliliği artırır.

- **Çevresel Etkiyi Azaltma:** NPK sensörleri, gereksiz ve aşırı gübre kullanımını önleyerek yer altı suyu kirliliği ve ekosistem zararlarını azaltır. Bu sayede çevresel etkiler en aza indirilir ve sürdürülebilir tarım uygulamaları desteklenir.

- **İzleme ve Yönetim Kolaylığı:** Gerçek zamanlı ölçüm yapabilen NPK sensörleri, tarım alanlarının sürekli izlenmesini sağlar. Bu sayede besin eksiklikleri veya dengesizlikleri erken tespit edilerek, çiftçilerin hızlı müdahale ile üretim kayıplarını önlemesi mümkün olur.

- **Sulama Planlaması:** NPK sensörleri, topraktaki besin elementlerinin yanı sıra nem seviyesini de ölçerek sulama süreçlerinin optimize edilmesini sağlar. Böylece su kaynakları verimli kullanılır, aşırı veya yetersiz sulamanın önüne geçilir ve bitki sağlığı korunur.

- **pH ve Tuzluluk Kontrolü:** NPK sensörleri, topraktaki pH ve tuzluluk seviyelerini sürekli izleyerek, bitki türüne uygun koşulların sağlanmasına yardımcı olur. Bu sayede besin emilimi maksimize edilir ve ürün verimliliği artırılır (Altıntaş, 2025).

3.1.1.3. NPK sensörlerinin sınırlamaları

- **Hassasiyet ve Kalibrasyon Gerekliliği:** NPK sensörlerinin ölçüm hassasiyeti, toprak tipi ve ortam koşullarına bağlı olarak değişebilir. Farklı topraklarda iyon hareketliliğinin farklılık göstermesi sensör performansını etkiler. Bu nedenle, sensörlerin doğru veri sağlayabilmesi için düzenli kalibrasyon gereklidir; aksi halde ölçüm sapmaları ve hatalı tarımsal uygulamalar ortaya çıkabilir.

- **Maliyet ve Erişilebilirlik Sorunları:** Gelişmiş NPK sensörleri, yüksek maliyetleri nedeniyle birçok tarım işletmesi için erişilebilir değildir. Özellikle küçük ölçekli veya düşük bütçeli üreticiler bu teknolojilere ulaşmakta zorluk yaşamaktadır. Yüksek birim fiyatları, teknolojinin yaygınlaşmasını ve kırsal bölgelerde benimsenmesini engellemektedir.

- **Çevresel Faktörlere Duyarlılık:** Toprak nemi, pH, sıcaklık ve elektriksel iletkenlik gibi çevresel değişkenler, NPK sensörlerinin ölçüm doğruluğunu doğrudan etkiler. Bu faktörlerdeki değişimler, sensörün hassasiyetini azaltarak hatalı veya tutarsız sonuçlara yol açabilir. Özellikle ekstrem koşullarda ciddi sapmalar görülebileceğinden, sensörlerin güvenilir veri üretebilmesi için kullanım koşulları dikkatle optimize edilmelidir (Altıntaş, 2025).

3.1.1.4. NPK sensörlerinin temel çalışma prensibi

- **Kimyasal Algılama Mekanizması:** NPK sensörleri, topraktaki kimyasal reaksiyonlar sonucu oluşan elektriksel değişimleri ölçerek çalışır. Azot, fosfor ve potasyum gibi besin maddeleri iyonik formda bulunur ve bu iyonların hareketi elektriksel iletkenlik, voltaj veya dirençte değişimlere neden olur. Sensör, bu değişiklikleri analiz ederek besin maddelerinin varlığını ve yoğunluğunu doğrudan sahada ve hızlı bir şekilde belirler.

- **Optik Algılama Yöntemi:** Optik tabanlı NPK sensörleri, toprağın ışıkla etkileşimi sonucu oluşan yansıtma ve emilim verilerini analiz ederek ölçüm yapar. Genellikle LED veya düşük güçlü lazerler ile belirli dalga boylarında ışık gönderilir ve toprağın bu ışığa verdiği tepki değerlendirilir. Bu yöntem, yüzeysel analizlerde hızlı ve temassız ölçüm imkânı sunar.

- **İyon Seçici Elektrotlar (ISE):** NPK sensörlerinde kullanılan iyon seçici elektrotlar, yalnızca belirli iyonlara duyarlı olup azot, fosfor ve potasyum iyonlarının yoğunluğunu doğrudan ölçer. Elektrot yüzeyindeki iyon alışverişi potansiyel farkına dönüştürülerek değerlendirilir. Bu yöntem, yüksek seçicilik

ve duyarlılığı sayesinde hassas tarım uygulamalarında yaygın olarak kullanılır (Altıntaş, 2025).

3.1.1.5. NPK sensörlerinin toprak ölçüm parametreleri

Çizelge 3.1 toprak analizinde kullanılan NPK sensörünün temel ölçüm parametreleri ve teknik özelliklerini özetlemektedir. Çizelgede sıcaklık, nem, iletkenlik, pH ve azot-fosfor-potasyum değerlerine ilişkin ölçüm aralıkları, doğruluk payları ve yanıt süreleri detaylandırılmıştır (Shenzhen Yingke Interactive Technology Co., Ltd., 2025).

Çizelge 3.1. NPK sensör toprak ölçüm parametreleri

Sıcaklık	• Ölçüm aralığı: -40°C-80°C • Doğruluk: ±5°C (25°C) • Uzun vadeli kararlılık: ≤%0.1°C/y • Tepki süresi: ≤15s
Nem	• Ölçüm aralığı: 0-100 bağıl nem • Doğruluk: %0-50 içinde %2, %50-100 içinde %3 • Uzun vadeli kararlılık: ≤%1 bağıl nem/y • Yanıt süresi: ≤4s
İletkenlik	• Ölçüm aralığı: 0-200 000 us/cm • Doğruluk: 0-10 000 us/cm aralığı ±%3; 10 000-20 000 us/cm aralığı ±%5 • Uzun vadeli kararlılık: ≤1%uS/cm • Yanıt süresi: ≤1s
pH	• Ölçüm aralığı: 3-9 PH • Doğruluk: ±0.3PH • Uzun vadeli kararlılık: ≤%5/yıl • Tepki süresi: ≤10S
Azot Fosfor Potasyum	• Ölçüm aralığı: 1-2999 mg/kg(mg/L) • Çözünürlük:1 mg/kg(mg/L) • Doğruluk: ≤%5 • Tepki süresi: <1S

3.1.1.6. NPK sensörlerinin özellikleri

Çizelge 3.2 kullanılan NPK sensörünün güç kaynağı, enerji tüketimi, koruma sınıfı, kablo uzunluğu, çalışma sıcaklığı aralığı ve genel boyutlarına ait teknik özellikler özetlenmiştir. Sensörün çevresel dayanıklılığı ve teknik gereksinimleri bu çizelge ile detaylandırılmıştır (Shenzhen Yingke Interactive Technology Co., Ltd., 2025).

Çizelge 3.2. NPK sensör özellikleri

Güç Kaynağı	DC4.5-30V
Maksimum Güç tüketimi	0.5W@24V DC
Koruma sınıfı	IP68, uzun süreli suya daldırma kullanımı
Kablo uzunluğu	2M
Çalışma ortamı	-40°C-80°C
Genel boyutlar	45 * 15 * 123mm

3.1.1.7. Kablolama

Çizelge 3.3'te NPK sensöründe kullanılan kabloların renklerine göre işlevleri gösterilmektedir. Güç bağlantıları ve iletişim hatlarının hangi renkle temsil edildiği detaylandırılmıştır (Shenzhen Yingke Interactive Technology Co., Ltd., 2025).

Çizelge 3.3. Kablolama özellikleri

Kablo rengi	Açıklama
Kahverengi	Power + (DC5-30V)
Siyah	Power -
Sarı/Yeşil	RS485 A+
Mavi	RS485 B-

3.1.2. Arduino UNO sensör

Arduino, İtalya'da geliştirilen ve üzerinde ATmega328 mikrodenetleyicisi bulunan açık kaynaklı bir elektronik geliştirme platformudur. Elektronik uygulamalarda en yaygın kullanılan modellerden biri olan Arduino Uno, özellikle düşük maliyeti, programlanabilir yapısı ve donanımsal esnekliği nedeniyle kullanıcılar arasında geniş bir kabul görmüştür. Kart üzerinde yer alan çok sayıda dijital ve analog giriş/çıkış pinleri, çeşitli sensörler, modüller ve aktüatörlerle kolay entegrasyon sağlamaktadır. Arduino, kullanıcı dostu geliştirme ortamı ve C/C++ tabanlı programlama dili desteği sayesinde hem kodlamaya yeni başlayan bireyler hem de ileri düzey elektronik projeler geliştiren uzman kullanıcılar tarafından etkin şekilde kullanılmaktadır. Ayrıca Arduino ailesi, farklı ihtiyaçlara yanıt verebilmek amacıyla Uno, Mega, Nano, Due, Esplora, LilyPad ve Pro Mini gibi çeşitli modellerle sunulmakta; bu da platformun farklı kullanım senaryolarına kolayca uyarlanmasını mümkün kılmaktadır. Arduino'nun kullanım alanlarına dair birkaç örnek vermek gerekirse; endüstri, sağlık,

savunma sanayi, nesne algılama, laboratuvarlar, tarım, trafik, akıllı ev sistemleri gibi pek çok farklı sektörde uygulanmaktadır.

3.1.2.1. Güç

Güç Besleme Seçenekleri: Arduino kartları, elektrik enerjisini USB bağlantısı veya harici adaptör yoluyla sağlayabilir. Harici adaptör kullanıldığında, 7–12 volt arası bir çıkış önerilir; kart teknik olarak 6–20 volt arası gerilimi tolere edebilir. Uygun voltaj aralığı dışına çıkılması kartın işlevselliğine zarar vereceğinden, üretici tavsiyelerine uyulmalıdır (Üren, 2023; Yılmaz, 2025).

Reset (Sıfırlama) Fonksiyonu: Arduino kartı üzerindeki reset butonu, yazılımı yeniden başlatmak için kullanılır ve genellikle güç girişine yakın bir konumdadır. Bu butona basıldığında mevcut program durur ve yeniden başlatılır. Özellikle devre değişikliği veya sistem kararsızlığı durumlarında, manuel sıfırlama ile sistemin istikrarı sağlanır. Güç kesilmedikçe, Arduino son yüklenen programı hafızasında tutarak çalıştırmaya devam eder (Üren, 2023; Yılmaz, 2025).

3.1.2.2. Arduino üzerindeki pinler

Dijital Pinler: Arduino Uno üzerinde, 0'dan 13'e kadar numaralandırılmış 14 dijital pin bulunur. Her pin, giriş (input) veya çıkış (output) olarak programlanabilir; bu sayede sensörlerden veri almak veya LED, röle ve motor sürücüsü gibi dış birimlere sinyal göndermek mümkündür.

0 ve 1 numaralı pinler, sırasıyla RX (veri alımı) ve TX (veri iletimi) fonksiyonlarına sahip olup, kartın bilgisayarla seri iletişimini sağlar. Program yükleme sırasında bu pinlerin başka donanımlarla bağlantılı olmaması önerilir.

3, 5, 6, 9, 10 ve 11 numaralı pinler PWM (Pulse Width Modulation) desteği sunar ve genellikle motor kontrolü, LED parlaklık ayarı ve ses uygulamalarında kullanılır. Bu pinler (~) sembolü ile işaretlenmiştir ve 0-255 arası dijital değerlerle çalışabilir. Tüm dijital pinler 5 volt gerilimle çalışır ve pin başına maksimum 40 mA akım sağlayabilir. Bu sınırın aşılması mikrodenetleyiciye zarar verebileceğinden, uygun direnç veya

akım sınırlayıcı kullanılması gerekir. Dijital pinler yalnızca dijital sinyallerle çalışır ve çıkışları LOW (0V) veya HIGH (5V) düzeyindedir (Üren, 2023; Yılmaz, 2025).

Analog Pinler: Arduino Uno kartında, analog sinyalleri dijital verilere dönüştüren altı adet analog giriş pini bulunur (A0–A5). Bu pinler, dış ortamdan gelen sürekli gerilim seviyelerini ölçmek için kullanılır. Kart üzerindeki 10 bit çözünürlüklü ADC, 0–5 volt arası analog sinyalleri 0–1023 arası dijital değerlere çevirir. Böylece potansiyometre, sıcaklık veya ışık sensörü gibi elemanlardan alınan analog veriler, mikrodenetleyici tarafından işlenebilir hale gelir. Analog pinler yalnızca giriş amaçlıdır ve dijital pinlerden farklı olarak sürekli değişen sinyallerin ölçümünü mümkün kılar (Üren, 2023; Yılmaz, 2025).

Güç Pinleri: Arduino Uno kartı üzerinde, farklı gerilim ve akım gereksinimlerine sahip bileşenlere enerji sağlamak amacıyla çeşitli güç pinleri bulunmaktadır:

- **Vin (Voltage In):** Vin pini, Arduino'nun harici güç kaynaklarıyla (adaptör veya pil) çalıştırılmasında kullanılır. 7–12 volt arası gerilim bu pine uygulanabilir ve kart üzerindeki regülatör aracılığıyla tüm sistemin enerji ihtiyacı karşılanır.

- **5V:** 5V pini, dahili regülatör tarafından sağlanan 5 voltluk çıkıştır. Özellikle 5V ile çalışan sensör, modül ve diğer devre elemanlarının beslenmesi için kullanılır. Kart USB veya Vin ile beslendiğinde de 5V çıkış sağlar.

- **3.3V:** 3.3V pini, kart üzerindeki voltaj regülatörü aracılığıyla düşük voltaj gerektiren bileşenlere 3.3 volt sağlar. Maksimum çıkış akımı yaklaşık 50 mA ile sınırlı olup, yüksek akım çeken bileşenlerde doğrudan kullanılması önerilmez.

- **GND (Ground):** GND pinleri, devreyi tamamlayan ve tüm güç ile sinyal pinlerinin referans noktası olan toprak bağlantılarıdır. Kart üzerinde birden fazla GND pini bulunur ve tüm devre elemanlarının ortak toprak hattına bağlanması gerekir (Üren, 2023; Yılmaz, 2025).

3.1.2.3. LED'ler

Arduino Uno kartı üzerinde yer alan dört adet yerleşik LED, sistemin çalışma durumu ve haberleşme süreçleri hakkında kullanıcıya görsel geri bildirim sağlamaktadır:

- **ON LED (Güç Göstergesi):** ON LED'i, Arduino kartının enerji aldığını ve aktif olduğunu gösterir. USB veya harici güç kaynağına bağlandığında otomatik olarak yanar ve kartın çalışır durumda olduğunun temel göstergesidir.

- **RX ve TX LED'leri (Seri İletişim Göstergeleri):** RX (alıcı) ve TX (verici) LED'leri, Arduino ile bilgisayar arasında veri iletimi sırasında yanıp söner. TX LED'i veri gönderildiğinde, RX LED'i ise veri alındığında aktif olur ve haberleşmenin izlenmesini sağlar.

- **L LED (Kullanıcı Kontrollü LED):** L harfiyle işaretlenen ve dijital 13. pine bağlı bu LED, genellikle test ve temel giriş-çıkış uygulamalarında kullanılır. Programlama ile kontrol edilebilir ve Arduino IDE'deki "Blink" örneğinde varsayılan olarak kullanılır (Üren, 2023; Yılmaz, 2025).

3.1.3. LCD ekran

Bu çalışmada, görsel verilerin kullanıcıya etkili bir biçimde sunulabilmesi amacıyla 1.8 inç boyutunda, 128x160 piksel çözünürlüğe sahip RGB TFT ekran modülü kullanılmıştır. TFT (Thin Film Transistor – İnce Film Transistör) teknolojisi ile üretilen bu ekranlar, her bir pikselin bağımsız olarak kontrol edilmesine olanak tanıyarak yüksek kontrast, parlaklık ve hızlı tepki süresi gibi avantajlar sunmaktadır. Bu özellikler, özellikle dinamik içeriklerin gösterimi ve kullanıcı arayüzünün okunabilirliğinin artırılması açısından önemli katkılar sağlamaktadır. RGB renk modeli üzerinden çalışan modül, 65 bin ile 262 bin renk aralığında görüntüleme desteği sunmakta; bu sayede daha gerçekçi ve detaylı bir görsel arayüz oluşturulmasına olanak vermektedir. Söz konusu ekran, mikrodenetleyicilerle genellikle SPI (Serial Peripheral Interface) haberleşme protokolü aracılığıyla iletişim kurmakta olup, düşük güç tüketimi sayesinde taşınabilir sistemlerde tercih edilen bir

bileşen hâline gelmiştir. Ekranın kompakt yapısı ve çok yönlü görselleştirme kapasitesi, bu modülü gömülü sistem uygulamaları açısından işlevsel bir tercih kılmaktadır (DirencNet, 2025). Çizelge 3.4 kullanılan LCD ekranın teknik özelliklerini özetlemektedir.

Çizelge 3.4. LCD ekran özellikleri

Ekran modu	A-TFT
Ekran Formatı	Grafik 128RGB * 160 Dot-Matrix
Çözünürlük	128RGB * 160 Nokta
Çalışma Sıcaklığı	-20°C ~ 70°C
LCD Aktif Alan	28.03 (W) * 35.04 (H)
Pin Tanımı	1-RST 2-CE 3-D/C 4-DIN 5-CLK 6-UCC 7-BL 8-GND

3.1.3.1. LCD ekran kullanım alanları

- Akıllı telefonlar
- Video oyunları
- Televizyonlar
- Gömülü sistemlerde veri görselleştirme
- Taşınabilir medikal cihazlar
- Kullanıcı arayüzlü kontrol panelleri
- Giyilebilir teknolojiler
- Hava durumu istasyonları (DirencNet, 2025)

3.1.4. RS485 dönüştürücü

RS485, özellikle veri toplama ve kontrol sistemlerinde kullanılmak üzere 1980'li yılların başlarında geliştirilmiş bir seri haberleşme protokolüdür. Günümüzde başta endüstriyel otomasyon olmak üzere, birçok uygulama alanında yaygın şekilde kullanılmaktadır. Bu haberleşme standardı, birden fazla cihazın aynı veri hattı üzerinden çift yönlü ve senkronize şekilde iletişim kurabilmesini mümkün kılar. RS485 protokolünün en önemli avantajlarından biri, veri iletimi sırasında ortak bir topraklama hattı gerektirmemesidir. Bu sayede sistem, endüstriyel ortamlarda sıkça karşılaşılan toprak potansiyeli farklarına karşı daha dayanıklı hâle gelir ve elektromanyetik parazit içeren zorlu koşullarda dahi güvenilir iletişim sürdürülebilir.

RS485 haberleşmesi, diferansiyel voltaj prensibine dayalı olarak çalışır. Bu yapı, sinyallerin "+" ve "–" hatları üzerinden iletilmesini sağlayarak elektromanyetik girişimlere karşı yüksek bağışıklık kazandırır. Ayrıca düşük voltajla çalışabilmesi ve uzun mesafeli iletime imkân tanıması, protokolün endüstriyel sistemlerde tercih edilme nedenlerinden biridir. RS485, bu teknik avantajları sayesinde bilgisayarlar, tıbbi cihazlar, robotik sistemler, bina otomasyonu ve kablosuz kontrol altyapıları gibi çok çeşitli alanlarda yaygın olarak kullanılmaktadır.

Sistem yapısı itibarıyla RS485 modülü, tek bir vericinin aynı hat üzerinden birden fazla alıcıya veri gönderebilmesine olanak tanır. Verici cihaz tarafından gönderilen veri, RS485 standardına uygun olarak iletim hattına aktarılırken, alıcı cihazlar bu veriyi okuyarak gerekli işlemleri yerine getirir. İki yönlü iletişimi destekleyen yapı sayesinde, alıcılar gerektiğinde yanıt sinyalleri ile geri bildirimde de bulunabilir. Bu çoklu iletişim kapasitesi, RS485'i özellikle merkezi kontrol sistemlerinde vazgeçilmez kılmaktadır (Özkaya, 2012; Mega Mühendislik, 2022).

3.1.4.1. RS485 dönüştürücü çalışma prensibi

RS485, çok noktalı seri iletişim mimarisiyle birden fazla cihazın aynı veri hattı üzerinden veri alışverişi yapmasını sağlar. Temel olarak, dengelenmiş (differential) sinyaller aracılığıyla iletim gerçekleşir ve bu yöntem, sinyal bütünlüğünü koruyup gürültüye karşı yüksek bağışıklık sağlar.

Veri iletimi, A ve B olarak adlandırılan iki hat üzerinden yapılır; bu hatlar zıt fazda çalışır ve alıcı devre, aralarındaki potansiyel farkı çözümleyerek veriyi okur. Bu yapı, elektromanyetik parazite karşı dayanıklılık sağlar ve özellikle endüstriyel ortamlarda güvenilir iletişim sunar.

Diferansiyel sürücüler, sinyallerin doğru seviyelerde iletilmesini garanti ederken, A ve B hatları üzerinden aşırı akıma karşı koruma sağlar. Böylece RS485 dönüştürücü devresi, haberleşmenin yanı sıra sistemin genel kararlılığını ve güvenliğini de destekler (Özkaya, 2012; Mega Mühendislik, 2022).

3.1.4.2. RS485 dönüştürücü özellikleri

Çift Hat Üzerinden Haberleşme: RS485 protokolü, yalnızca iki kablo ile veri iletimini ve alımını mümkün kılar; böylece kablolama maliyetini ve kurulum karmaşıklığını azaltır.

Çok Yönlü (Duplex) İletişim Desteği: RS485, hem yarı-duplex hem de tam-duplex iletişimi destekleyerek noktadan noktaya veya çok noktalı topolojilerde esnek kullanım imkânı sunar.

Yüksek Veri İletim Hızı: Teorik olarak 35 Mbps'ye kadar veri hızını destekleyen RS485, hızlı ve gecikmesiz iletişim gerektiren endüstriyel otomasyon sistemlerinde tercih edilir.

Termal Koruma Özelliği: RS485 dönüştürücüleri, entegre termal koruma ile aşırı ısınmaya karşı güvence sağlar; giriş konnektörlerindeki dirençler ise yüksek akım geçişlerine karşı koruma sunar.

Uzun Mesafe Desteği: Uygun sonlandırma ve burulmuş çift kablo kullanımı ile RS485, 1200 metreye kadar güvenilir iletişim sağlar ve geniş alanlarda avantaj sunar.

Sonlandırma Direnci Kullanımı: Hat uçlarındaki 120 ohm'luk dirençler, sinyal yansımasını önler ve burulmuş kablo yapısı, elektromanyetik paraziti azaltır.

Topraklama Farklarına Karşı Tolerans: RS485, cihazlar arasında ±7V'a kadar toprak potansiyeli farkını tolere edebilir ve endüstriyel ortamda kararlılığı artırır.

Çoklu Cihaz Desteği: Bir veri hattında bir verici ve 32 alıcıya kadar cihaz desteklenir; toplam akım sınırı (60 mA) sistem istikrarı için göz önünde bulundurulmalıdır.

Veri Bütünlüğü ve Güvenliği: RS485, hata algılama ve düzeltme mekanizmalarını destekleyerek iletim sırasında veri bütünlüğünü ve güvenliğini sağlar.

Esnek Mimarî Yapı:RS485, iletim katmanına teknik standart getirirken üst katman protokolleri geliştiriciye bırakır; bu esneklik, farklı uygulamalara kolay entegrasyon sağlar (Özkaya, 2012; Mega Mühendislik, 2022).

3.1.4.3. RS485 dönüştürücü kullanım alanları

RS485 dönüştürücü modülü günlük hayatta pek çok alanda karşımıza çıkmaktadır. Bu kullanım alanlarını endüstriyel otomasyon sistemleri, üretim hatlarındaki sensörler, kontrol cihazları, enerji yönetim sistemleri, bina otomasyonu, yüz tanıma-parmak izi okuma, kart okuyucu sistemler şeklinde sıralanabilir (Özkaya, 2012; Mega Mühendislik, 2022).

3.1.5. Yapay zekâ sistemi

Yapay zekâ, bilgisayarların veya bilgisayar destekli yazılımların; algılama, karar verme, bilgi depolama, problem çözme, düşünme ve genelleme gibi insan zekâsına özgü bilişsel işlevleri taklit edebilmesine olanak tanıyan bir teknolojidir. Bu teknolojinin temelinde, sistemin öğrenme yetkinliği yer almaktadır. Yapay zekâ yalnızca günlük yaşamı pratik hâle getirmekle sınırlı kalmamakta, aynı zamanda bireylerin yaşam kalitesini artırmaya yönelik çeşitli uygulama alanları sunmaktadır.
Yapay zekânın kullanım amaçları üç ana başlık altında sınıflandırılabilir:

- **Bilimsel Amaç**: Yapay zekâ uygulamalarının bilimsel hedefi, biyolojik sistemlerin işleyişini modelleyerek zekânın doğasını ve sınırlarını anlamaktır. Bu yaklaşım, insan beyninin çalışma prensipleri ve bilişsel sınırları gibi sorulara yanıt arayarak yapay sistemlerle bilişsel bilimler arasında teorik ve uygulamalı bir köprü kurmayı amaçlar.

- **Eğitim Amacı**: Yapay zekâ destekli sistemlerin eğitimde temel amacı, bireylerin öğrenme kapasitesini ve muhakeme becerilerini artırmaktır. Bu amaçla, teknolojik gelişmeleri takip etmelerini ve Ar-Ge süreçlerine katılımlarını destekleyen simülasyonlar, etkileşimli yazılımlar ve yenilikçi müfredatlar sunulmaktadır. Ayrıca, öğreticilerin problem çözme ve strateji

geliştirme yetkinlikleri çeşitli kurslar ve seminerlerle sistematik olarak geliştirilmektedir.

- **Mühendislik Amacı**: Yapay zekânın mühendislikteki temel amacı, gerçek dünya koşullarında bağımsız kararlar alabilen ve çevresine akıllı tepkiler verebilen yazılım ve özerk robot sistemleri geliştirmektir. Bu yaklaşım, endüstriyel uygulamalarda verimlilik ve kaliteyi artırırken, iş kazası risklerini de azaltma potansiyeline sahiptir (Bozüyük vd., 2005).

3.1.5.1. Yapay zekâ sistemi yöntemleri

Yapay zekâ sistemleri geliştikçe birçok alt başlığa ayrılmıştır. Birbirlerinden uygulama yöntemleri ve hitap ettikleri problemler açısından ayrılan bu alt başlıklar temelde uzman sistemler, yapay sinir ağları, bulanık mantık, genetik algoritmalar ve makine öğrenmesi olarak listelenebilir (Öztürk ve Şahin, 2018).

Makine Öğrenmesi

Makine öğrenmesi, geçmişte elde edilen verilerden öğrenerek bu bilgileri belleğinde tutabilen ve benzer bir problemle karşılaştığında karar verme yetisi sergileyebilen bir yapay zekâ alt alanıdır. Aynı zamanda, üzerinde çalıştığı problemi bağımsız şekilde çözebilen, karmaşık veri yapıları arasında anlamlı ilişkiler kurabilen ve bu ilişkiler doğrultusunda karar verebilen bilgisayar algoritmalarının bütünüdür (Bayrakçı vd., 2021). Bu yaklaşımın temelinde, bilgisayar sistemlerinin dışarıdan açıkça programlanmaksızın öğrenme yeteneği kazanması ilkesi yer almaktadır (Öztürk ve Şahin, 2018). Mevcut veri setlerinden elde edilen bilgiler doğrultusunda oluşturulan algoritmalar, yüksek verimlilik sağlamayı hedefleyerek tasarlanmaktadır. Bu doğrultuda, farklı veri yapıları ve problemler için çeşitli makine öğrenmesi modelleri geliştirilmiştir. En yaygın kullanılan modeller arasında destek vektör makineleri, yapay sinir ağları, k-en yakın komşu algoritması, k-ortalama kümeleme algoritması, karar ağaçları ve lojistik regresyon analizi yer almaktadır (Atalay ve Çelik, 2017). Makine öğrenmesi, yapay zekânın bir alt kümesini oluştururken, aynı zamanda derin öğrenme yöntemlerini de kapsayan üst düzey bir çatı konumundadır. Makine öğrenimi şeması Şekil 3.1'te gösterilmektedir (Gökalp, 2021).

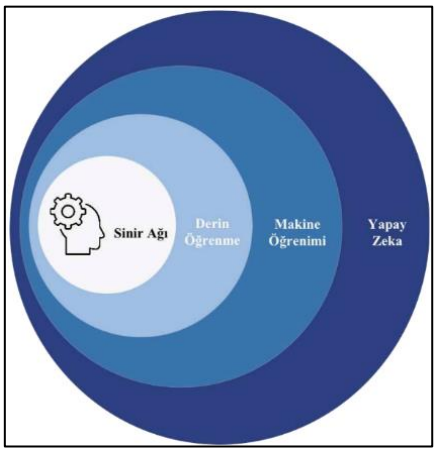

Şekil 3.1. Makine öğrenimi şeması (Gökalp, 2021)

Söz konusu algoritmalar, en isabetli tahminleri gerçekleştirebilmek ve doğru kararlar alabilmek amacıyla sistematik olarak eğitilmektedir. Algoritmaların doğruluk oranları, işlenen veri miktarının artmasıyla birlikte yükselmektedir. Günümüzde veri hacminin ve veri yapısının karmaşıklığının artması, bu verilerin analiz edilmesini ve anlamlandırılmasını güçleştirmektedir. Bu noktada devreye giren makine öğrenmesi algoritmaları, büyük ve karmaşık veri kümelerini analiz ederek anlamlı ve doğru sonuçlara ulaşılmasını sağlamaktadır (Gökalp, 2021). Programlama yoluyla açıkça yönlendirilmeden, yalnızca girdi verileri üzerinden bilgisayarların öğrenme yeteneği kazanmasını amaçlayan makine öğrenmesi süreci belirli aşamalardan oluşmaktadır. Bu süreç sırasıyla: veri toplama, özellik (öz nitelik) çıkarımı, model seçimi, modelin eğitimi ve modelin değerlendirilmesi olmak üzere beş temel adımdan meydana gelir (Eker vd., 2023). Makine öğrenmesi algoritmaları üç temel kategoriye ayrılır:

1. Denetimli öğrenme
2. Denetimsiz öğrenme
3. Pekiştirmeli öğrenme

Makine öğrenmesinin tarihsel süreci, 20. yüzyılın ortalarına kadar uzanır ve şu şekilde özetlenebilir:

- 1950 yılında Alan Turing, bilgisayarların insanlar ile aynı zekayı sergileyip sergileyemeyeceğini test etmek amacıyla bir deney yapmıştır. Turing testi adı verilen bu uygulama, makine öğrenmesinin temellerini oluşturmuştur.
- 1956 yılında John McCarthy tarafından ilk kez yapay zekâ terimi bir konferansta kullanılmıştır. Takip eden yıllarda, tarihteki ilk yapay zekâ

programı olarak kabul edilen Logic Theorist, Allen Newell ve Herbert Alexander Simon tarafından geliştirilmiştir. Bu yapay zekâ programının amacı, bilgisayarlara insan aklına benzer şekilde mantıksal akıl yürütme yeteneği kazandırmaktır.

- 1959 yılında Arthur Samuel, kendi kendine gelişen ve satranç benzeri dama oyunu oynayabilen bir yazılım geliştirerek ilk kez makine öğrenmesi kavramını kullanmıştır.
- 1967 yılında Nearest Neighbor algoritması geliştirilerek örüntü tanıma uygulamalarının temeli atılmıştır.
- 1980'li yıllar, özellikle yapay sinir ağlarının rağbet gördüğü bir dönemdir. Makine öğrenmesi uygulamalarının daha sistematik hale gelmesiyle birlikte, istatistiksel yöntemler yaygınlaşmıştır.
- 1997 yılında IBM tarafından geliştirilen Deep Blue, dünya satranç şampiyonu Garry Kasparov'u yenmiştir.
- 2006 yılına gelindiğinde, çok katmanlı sinir ağları üzerine yapılan çalışmalar hız kazanmıştır. Bu durum, Geoffrey Hinton'un derin öğrenme kavramını gündeme getirmesiyle olmuştur.
- 2012 yılında AlexNet, ImageNet yarışmasında büyük bir başarı göstererek, görüntü tanıma ve bilgisayarla görme alanında yeni bir dönemin başlangıcını simgelemiştir.
- 2015 yılında Baidu tarafından geliştirilen süper bilgisayar Minwa, evrişimli sinir ağı (Convolutional Neural Networks, CNN) kullanarak görüntüleri, bir insandan daha yüksek doğruluk oranıyla tanıma ve kategorize etme başarısını göstermiştir.
- 2016 yılında Google DeepMind'ın geliştirdiği AlphaGo, beş oyunluk bir maçta dünya şampiyonlarını yenmiştir (Newell ve Simon, 1956; Samuel, 1959; Epstein vd., 2009; Silver vd., 2016; Krizhevsky vd., 2017).

3.1.5.2. Yapay zekâ sistemi uygulama alanları

Sağlık Hizmetleri: Yapay zekâ, tıbbi görüntüleme, tanı sistemleri, hasta takibi ve kişiselleştirilmiş tedavi planlaması gibi alanlarda etkin şekilde kullanılmaktadır. Ayrıca genetik analiz ve ilaç keşfi süreçlerinde de önemli rol oynamaktadır.

Finans ve Bankacılık: Finans sektöründe yapay zekâ, dolandırıcılık tespitinden kredi skorlamaya kadar çeşitli uygulamalara sahiptir. Ayrıca müşteri hizmetlerinde de süreçleri hızlandıran ve verimliliği artıran çözümler sunmaktadır.

Üretim: Kalite kontrol ve arıza tahmininden akıllı üretim sistemlerine kadar uzanan yapay zekâ uygulamaları, lojistik süreçlerin de optimize edilmesini sağlar.

Otomotiv ve Ulaşım: Gelişmiş sürücü destek sistemleri, trafik yönetimi, rota optimizasyonu ve otonom araç teknolojileri, ulaşımda yapay zekânın sunduğu yenilikler arasındadır.

Eğitim: Öğrenci başarısını tahmin etmekten kişiselleştirilmiş öğrenme ortamlarının oluşturulmasına, otomatik sınav değerlendirmesi ve dil öğrenme asistanlarına kadar pek çok eğitim uygulamasında yapay zekâdan yararlanılmaktadır.

Güvenlik: Plaka ve yüz tanıma, şüpheli hareket tespiti ile siber güvenlik tehditlerinin analizi gibi alanlarda güvenlik sistemleri, yapay zekâ ile daha etkin hâle gelmektedir.

Tarım: Mahsul tahmini, hastalık tespiti, akıllı sulama sistemleri ve hava durumu analizleri, tarımsal üretimde verimliliği artırmak amacıyla yapay zekâdan faydalanılan başlıca uygulama alanlarıdır.

Ticaret: Ürün öneri sistemleri, stok yönetimi, müşteri davranış analizi ve satın alma tahminleriyle birlikte finansal risk ve borsa analizlerinde de yapay zekâ önemli rol oynamaktadır.

Enerji-Otonom Sistemler ve Akıllı Şebekeler: Enerji tüketimi öngörüsü, yenilenebilir kaynakların yönetimi, endüstriyel robotlar ile otonom araç ve dronlar bu alandaki başlıca uygulamalardandır.

Doğal Dil İşleme: Metin anlama ve üretimi, otomatik çeviri, sesli asistanlar ve duygu analizi, doğal dil işleme teknolojilerinin temel kullanım alanlarını oluşturur.

Görüntü İşleme: Yapay zekâ, yüz tanıma, nesne tespiti ve takibi ile medikal görüntülerin analizinde kullanılmaktadır. Ayrıca otonom araçlarda kamera sistemlerinin işlevselliği de bu teknolojilere dayanmaktadır (İkas, 2025; Özcan, 2025).

3.1.6. Web sayfası

Günümüzde teknolojik gelişmelerin ivme kazanmasıyla birlikte, pek çok sektörde dijitalleşme odaklı dönüşümler yaşanmakta; bu dönüşüm sürecinin merkezinde ise internet teknolojileri yer almaktadır. İnternet altyapılarının hızlı gelişimi, bilgiye erişim biçiminden iş yapma modellerine kadar birçok alanda köklü değişikliklere yol açmış ve buna bağlı olarak yeni iş tanımları ortaya çıkmıştır. Her ne kadar bu roller geçmişte de farklı biçimlerde var olmuş olsa da günümüzde internet projelerinin sahip olduğu kapsam ve altyapı gereksinimleri, bu alanların uzmanlaşmış rollere ayrılmasını zorunlu hâle getirmiştir. Bu kapsamda, iş yükü farklı uzmanlık alanlarına dağıtılarak ekiplerin daha verimli çalışması ve projelerin daha sürdürülebilir biçimde yürütülmesi sağlanmıştır. Bu yaklaşım hem zaman tasarrufu hem de ekonomik verimlilik açısından önemli katkılar sunmaktadır. Bu bağlamda, modern bir internet sitesinin temelini oluşturan iki yapı olan frontend (kullanıcı arayüzü) ve backend (sunucu tarafı iş mantığı) kavramları öne çıkmaktadır.

3.1.6.1. Frontend

Frontend, kelime anlamı itibarıyla "ön yüz" olarak tanımlanmakta olup, kullanıcıların internet sitelerinde ya da uygulamalarda doğrudan etkileşimde bulunduğu kısmı ifade etmektedir. Bir web sitesinin ya da mobil uygulamanın açıldığında görülen metinler, grafikler, butonlar, tablolar ve görseller gibi tüm görsel ve işlevsel öğeler frontend kapsamına girmektedir. Frontend geliştirme sürecinde en sık kullanılan teknolojiler arasında HTML (sayfa yapısının oluşturulması; başlıklar, paragraflar vb.), CSS (görsel düzenlemelerin yapılması; renk, yazı tipi, hizalama gibi) ve JavaScript (kullanıcı etkileşimlerinin yönetilmesi; buton tıklamaları, form işlemleri, dinamik içerikler gibi) yer almaktadır. Bu temel teknolojilere ek olarak, modern frontend geliştirme süreçlerinde React, Angular ve Vue gibi JavaScript tabanlı kütüphaneler ve framework'ler de yoğun şekilde kullanılmakta; bu sayede daha dinamik, ölçeklenebilir

ve kullanıcı dostu arayüzler oluşturulabilmektedir (Infotech Academy, 2023; Coderspace, 2025a).

3.1.6.2. Backend

Backend, kelime anlamı itibarıyla “arka yüz” anlamına gelmekte olup, bir web sitesi ya da uygulamanın sunucu taraflı mimarisini ifade eder. Sistem mimarisinin temelini oluşturan backend, uygulamanın veri yönetimini, iş mantığını ve sunucu-istemci arasındaki iletişimi kontrol eden katmandır. Kullanıcı arayüzünde gerçekleşen işlemlerin arka planda doğru şekilde çalışmasını sağlar. Uygulamanın işlevselliği ve veri tutarlılığı açısından kritik bir rol üstlenen backend yapılar, farklı programlama dilleri ve çerçeveler (framework) kullanılarak geliştirilebilmektedir. Yaygın olarak kullanılan bazı backend teknolojileri aşağıda sınıflandırılmıştır:

- JavaScript tabanlı teknolojiler: Node.js, Meteor.js, Express
- PHP tabanlı çerçeveler: Symfony, Laravel, CodeIgniter, CakePHP
- Kotlin: Spark, Javalin
- Python: Flask, Django, CherryPy, Pyramid
- Java: Blade, Dropwizard, Spring, Grails
- Ruby: Ruby on Rails, Grape, Padrino, Sinatra
- Perl: Catalyst, Dancer, Mojolicious
- Go (Golang): Beego, Gin, Echo
- C++: Qt, Boost
- C#: .NET, Xamarin (Infotech Academy, 2023; Coderspace, 2025b).

3.1.6.3. API temelleri

FastAPI, Sebastián Ramírez tarafından 2018 yılında geliştirilen, API tabanlı web uygulamaları oluşturmak için kullanılan modern ve yüksek performanslı bir Python framework’üdür. Özellikle hızlı çalışması, düşük gecikme süresi ve asenkron işlem desteği sayesinde geliştiriciler tarafından sıkça tercih edilmektedir. Python'un tip ipuçlarını (type hints) etkin bir şekilde kullanarak veri doğrulama süreçlerini kolaylaştırır; böylece kodun okunabilirliğini ve güvenilirliğini artırır. FastAPI, OpenAPI ve JSON Schema standartlarına dayalı olarak otomatik dokümantasyon

üretme yeteneğine sahiptir ve bu sayede Swagger UI ile ReDoc gibi arayüzler üzerinden API uç noktalarının görsel olarak test edilmesini sağlar. Ayrıca WebSocket bağlantılarını desteklemesi sayesinde gerçek zamanlı veri akışına olanak tanır. Bu özellikleriyle FastAPI, geliştiricilerin daha hızlı, sürdürülebilir ve güvenli uygulamalar geliştirmelerine olanak sağlayan kapsamlı bir araç seti sunmaktadır (Chen, 2023; Rasulov, 2024).

POST metodu, HTTP protokolü kapsamında kullanılan temel istek (request) yöntemlerinden biridir ve istemciden sunucuya veri gönderilmesini sağlar. Bu yöntem, genellikle dosya yüklemeleri, form verilerinin işlenmesi, yeni kaynakların oluşturulması ve API çağrılarının gerçekleştirilmesi gibi işlemlerde yaygın şekilde kullanılmaktadır. POST isteği ile gönderilen veriler, URL içerisinde değil, isteğin gövdesinde taşındığı için hassas bilgilerin gizliliği daha iyi korunur; bu da güvenlik açısından önemli bir avantaj sunar. Ancak veri aktarımının güvenliğini tam olarak sağlamak için HTTPS protokolü ile birlikte kullanılması önerilmektedir. Ayrıca POST istekleri tarayıcılar tarafından önbelleğe alınmaz, bu nedenle her istek sunucu tarafından dinamik olarak işlenir ve güncel içeriklerin iletilmesini mümkün kılar. Bu özelliği sayesinde, özellikle kullanıcıdan alınan girdilere dayalı olarak anlık işlem yapılması gereken sistemlerde önemli bir rol oynamaktadır (Alam vd., 2014).

Endpoint, bir API'nin belirli bir işlevini veya kaynağını temsil eden URL adresi olup, farklı yazılım sistemlerinin birbirleriyle veri alışverişi yapabilmesine olanak sağlayan dijital erişim noktalarıdır. İstemciler, HTTP protokolü aracılığıyla belirli bir endpoint'e istek göndererek veri gönderme, veri alma veya belirli bir işlemi tetikleme gibi işlemleri gerçekleştirirler. Her endpoint, gerçekleştireceği işleve göre yapılandırılmış olup, temel bileşenleri arasında HTTP metodu (örneğin GET, POST), URL yolu (kaynağın adresi) ve isteğe özel parametreler yer alır. Endpoint'ler sayesinde API'lar modüler bir yapıya kavuşur; bu da sistemin daha kolay geliştirilebilir, yönetilebilir ve sürdürülebilir olmasını sağlar. Bir API'nın dış dünya ile kurduğu iletişim bu endpoint'ler üzerinden gerçekleşir ve her biri, sistemin belirli bir işlevini dışa açan kontrollü bir geçit niteliği taşır (Infoldia, 2022; UltaHost, 2024; PSA Teknoloji, 2025).

3.2. Yöntem

Bu çalışma, birden fazla bileşenin bütünleşik biçimde bir araya getirilmesiyle oluşturulmuştur.

Birinci aşamada, NPK sensörünü temel alan bir Arduino devresi tasarlanmıştır. Bu sistemin çalışma prensibi şu şekilde özetlenebilir: NPK sensörü, ölçüm için gerekli temel çevresel koşullar sağlandığında, toprak içerisindeki azot, fosfor ve potasyum değerlerini belirlemek üzere bir veri üretir. Arduino kartı, RS485 seri haberleşme protokolü aracılığıyla sensörle iletişim kurar ve üretilen verileri alır. Elde edilen bu veriler işlenerek topraktaki N, P ve K miktarları hesaplanır ve LCD ekran aracılığıyla kullanıcıya sunulur. Kurulan sistemin doğruluğunu test etmek amacıyla, aynı toprak örnekleri Isparta İl Özel İdaresi tarafından yapılan laboratuvar analizleriyle karşılaştırılmıştır. Bu karşılaştırmanın sağlıklı bir biçimde yapılabilmesi için her iki veri kümesindeki ölçümler ortak birimlere dönüştürülmüş ve analizler bir karşılaştırma tablosu üzerinde gerçekleştirilmiştir.

İkinci aşamada, Isparta İl Özel İdaresi tarafından geçmiş yıllarda gerçekleştirilen toprak analizlerinden elde edilen Tip 1 toprak analizi sınıfına ait veriler Excel formatına aktarılmıştır. Toplamda 5 024 adet veri kullanılarak elma, kayısı, kiraz, ceviz, lavanta ve gül olmak üzere altı farklı ürün deseni üzerinde çalışılmıştır. Analiz parametreleri olarak ilçe bilgisi, fosfor, potasyum ve pH değerleri dikkate alınmıştır. Geliştirilen sistemin temel hedefi, bu dört giriş parametresine dayanarak topraktaki satürasyon, kireç oranı ve organik madde miktarını tahmin etmektir. Burada dikkat edilmesi gereken önemli bir husus, yapılan tahminleme sonuçlarının çiftçilerin daha önceki yıllarda yaptığı analiz sonuçlarından yola çıkılarak yapılmış olmasıdır.

Üçüncü ve son aşamada, tüm bu girdi ve çıktı verileri bir arayüz aracılığıyla sunulmuştur. Böylece çiftçilerin kendi arazilerine özgü analiz verilerini değerlendirerek, uygun ürün tercihinde bulunmaları sağlanmıştır.

3.2.1. NPK sistem

Isparta ilinin farklı ilçelerinden toprak numuneleri toplanmıştır. Bu numuneleri elde ederken aşağıdaki adımlar izlenmiştir;

- Arazinin 7-8 farklı noktasından toprak alınarak harmanlanmıştır.
- Bu toprak kümeleri ortalama 0-30 cm derinlikten alınmıştır.
- Numune içerisinden taş, çöp, yaprak, kök gibi istenmeyen cisimler uzaklaştırılmıştır.
- Ortalama 1kg kadar toprak numunesi elde edilmiştir.
- Elde edilen numune poşetlerine etiketleme yapabilmek amacıyla numaralar verilmiştir.
- 6 farklı bölgede bu işlemler tekrarlanarak numuneler oluşturulmuştur.

NPK sensörü, toprakta bulunan azot, fosfor ve potasyum miktarlarını ölçmeye yarayan bir cihazdır. Sağlıklı ve güvenilir bir ölçüm elde edilebilmesi için, sensörün yerleştirileceği toprak örneğinin büyük taş parçacıkları, yabancı maddeler ve ot gibi organik artıklar içermemesi gerekmektedir. Bu nedenle, analiz amacıyla farklı bölgelerden toplanan ve numaralandırılan toprak örneklerinin tamamı, önce elenerek bu tür istenmeyen bileşenlerden arındırılmıştır. Bu işlem aynı zamanda toprağın havalanmasını da sağlamış ve ölçüm koşullarını iyileştirmiştir.

Sensörün doğru çalışabilmesi için bir diğer önemli koşul ise toprağın yeterli düzeyde ıslak olmasıdır. NPK sensörü, ölçüm işlemini suyun iletkenlik özelliğinden yararlanarak gerçekleştirmektedir. Bu bağlamda, her bir numune uygun bir kaba alınmış ve üzerine su eklenerek çamur kıvamına getirilmiştir. Ardından NPK sensörü bu karışıma daldırılarak ölçümler yapılmış ve elde edilen veriler kayıt altına alınmıştır.

Arduino mikrodenetleyicisinin UART portu (TX/RX pinleri), RS485 modülü aracılığıyla NPK sensörü ile iletişim kurmaktadır. Bu haberleşme sürecinde, Arduino'nun TX (transmit) pini RS485 modülüne veri iletirken, RX (receive) pini aracılığıyla modülden gelen veriyi almaktadır. Arduino, RS485 üzerinden sensörden aldığı verileri işler ve elde edilen sonuçları bağlı LCD ekran üzerinde kullanıcıya

sunar. Öte yandan, Tip 1 toprak analizi, çiftçiler tarafından en yaygın şekilde tercih edilen toprak analiz türüdür. Bu analiz yöntemi kapsamında toprağın şu temel özellikleri belirlenmektedir; satürasyon oranı, pH düzeyi, toplam tuz miktarı, kireç miktarı, organik madde miktarı, fosfor içeriği ve potasyum içeriği. Bu parametreler, toprağın verimliliği ve uygun gübreleme stratejileri açısından kritik öneme sahiptir. Elde edilen veriler hem ürün seçiminde hem de toprağın iyileştirilmesine yönelik müdahalelerde bilimsel dayanak sunmaktadır. Kullanılan toprak numuneleri ve analiz ölçümleri Şekil 3.2 ve Şekil 3.3 ile verilmiştir.



Şekil 3.2. Toprak numuneleri

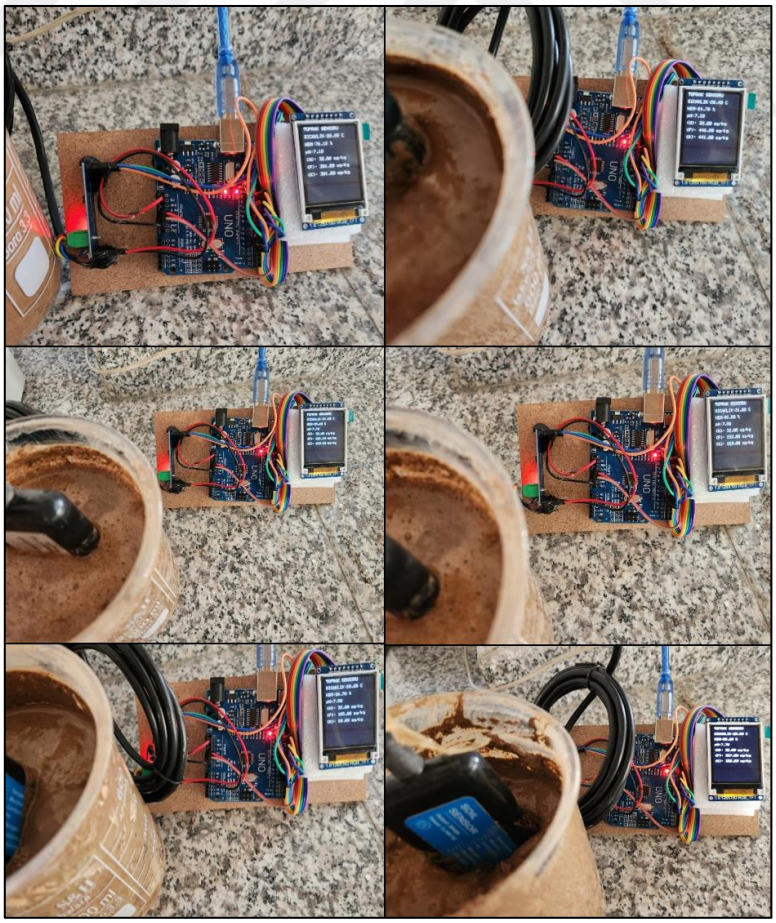

Şekil 3.3. Toprak ölçüm görselleri

Ölçümleri ve analizleri tamamlanan toprak numuneleri kaydedilmiştir. Bu kayıtlar doğru karşılaştırma yapılabilmesi için aynı birimlere dönüştürülmüştür. NPK sensör ile yapılan ölçümde fosfor değeri için kalibrasyon yapılmıştır. Çizelge 3.5 ve Çizelge 3.6 ile ölçüm sonuçlarına ulaşılabilmektedir.

Çizelge 3.5. Toprak numuneleri NPK ölçüm sonuçları

Ölçümler	**140**	**145**	**150**	**155**	**160**
ph	nötr	hafif alkali	hafif alkali	nötr	hafif alkali
P(mg/kg)	düşük	çok düşük	düşük	çok düşük	çok düşük
K(mg/kg)	çok yüksek	yüksek	çok yüksek	çok yüksek	düşük

Çizelge 3.6. Toprak numuneleri il özel idare ölçüm sonuçları

İl Özel İdare Ölçüm	**140**	**145**	**150**	**155**	**160**
ph	nötr	hafif alkali	hafif alkali	nötr	hafif alkali
P(kg/da)	düşük	az	az	az	çok az
K(kg/da)	yüksek	yüksek	yüksek	yüksek	az

Ölçüm değerleri ile analiz sonuçlarının birbiri ile örtüşüyor olması kurulan sensör ağının güvenilirliğini sağlamaktadır. İkinci aşama, elde edilen bu verilerin işlenip anlamlı birer bilgi haline getirilmesidir.

3.2.2. Python yazılım

Isparta İl Özel idareden elde edilen veriler excel dosyası haline getirilmiş ve yapay zekâ sisteminde kullanılmak üzere 6 temel grupta (ceviz, elma, gül, kayısı, lavanta, kiraz) toplanarak toplamda 5 024 farklı veri kümesi oluşturulmuştur. İlgili Python kütüphanelerinin koda dâhil edilmesiyle çalışmaya başlanmıştır;

- Veri işleme işlemleri için pandas ve numpy,
- Makine öğrenmesi modellerinin inşası için xgboost ve scikit-learn,
- Kategorik değişkenlerin dönüştürülmesi için LabelEncoder,
- Modelin performans değerlendirmesi için accuracy_score, classification_report ve mean_squared_error,
- Veri görselleştirme amacıyla matplotlib,
- Modelin kaydedilmesi ve yeniden yüklenmesi için pickle ve joblib kütüphanelerinden faydalanılmıştır.

Veri ön işleme aşamasında, Data tablosundaki potasyum, fosfor, pH, satürasyon, kireç ve organik madde değişkenleri sayısal verilerden kaynaklanabilecek dönüştürme hatalarını önlemek için dönüşüm aşamalarından geçirilmiştir. Ayrıca, makine öğrenmesi algoritmalarında kullanılabilmeleri için kategorik veriler LabelEncoder ile sayısal değerlere dönüştürülmüştür.

Temel hazırlık aşamalarının ardından XGBoost regresyon modeli kullanılarak "satürasyon" değişkeninin tahmin edilmesi hedeflenmiştir. Bu doğrultuda uygulanan adımlar aşağıda sıralanmıştır:

1. **Veriyi hazırlama:** Bağımlı (y) ve bağımsız (X) değişkenler tanımlanarak, "ilce_encoded", "potasyum", "fosfor" ve "ph" bağımsız; "saturasyon" ise bağımlı değişken olarak seçilmiştir. Veri seti, %80 eğitim ve %20 test olmak üzere rastgele ikiye ayrılmıştır
2. **Hiperparametre Araması (RandomizedSearchCV):** XGBoost algoritmasında hiperparametre optimizasyonu için RandomizedSearchCV kullanılmıştır. Belirlenen parametre aralıklarında rastgele denemeler yapılarak, en iyi performans veren parametre kombinasyonu bulunmuştur. RandomizedSearchCV, 200 farklı parametre kombinasyonunu üç katlı çapraz doğrulama ile test etmiş ve negatif ortalama kare hata (neg_mean_squared_error) metriği kullanılmıştır. İşlem çok çekirdekli paralel olarak yürütülmüş, en başarılı parametreler best_params_ değişkeninde toplanmıştır.
3. **En İyi Parametrelerle Modeli Eğitme:** En iyi hiperparametrelerle model eğitimi aşamasında, best_params sözlüğünden tree_method çıkarılarak yeni bir best_params_cleaned oluşturulmuş ve model bu parametrelerle tanımlanmıştır. Ortalama kare hata kayıp fonksiyonu kullanılmış, ağaç yapılandırma yöntemi olarak ise tree_method='hist' seçilmiştir. Böylece, optimizasyon sonrası en uygun ayarlarla yüksek performanslı bir XGBRegressor modeli eğitilmiştir.
4. **Modeli Eğitme (DMatrix ile):** Model eğitimi için veri setleri XGBoost'un optimize edilmiş DMatrix formatına dönüştürülmüştür. X_train ve y_train ile model eğitilmiş, X_test ve y_test ise doğrulama için kullanılmıştır. Eğitimde erken durdurma uygulanmış, hata 10 ardışık iterasyonda iyileşmezse süreç

sonlandırılmıştır. Ayrıca, eğitim süreci boyunca her 50 iterasyonda bir güncel bilgiler ekrana yazdırılmıştır.

5. **Tahmin ve Performans Ölçme:** Modelin tahmin performansı, test verisi üzerinden elde edilen veriler ile değerlendirilmiştir. Sonuç, dört ondalık basamağa yuvarlanarak ekrana yazdırılmıştır.
6. **Feature Importance (Özellik Önem Skoru):** Modelde hangi bağımsız değişkenlerin daha belirleyici olduğunu görmek için xgb.plot_importance fonksiyonu ile özellik önem skoru görselleştirilmiştir. importance_type="weight" parametresiyle, her bir özelliğin karar ağaçlarında kullanılma sıklığına göre önem derecesi belirlenmiş; sonuçlar "Feature Importance (Saturasyon Tahmini)" başlığıyla grafik olarak sunulmuştur.

Bu aşamada, best_params sözlüğünden tree_method çıkarılarak yalnızca gerekli hiperparametreleri içeren best_params_cleaned oluşturulmuştur. Ardından, bu parametrelerle XGBRegressor modeli tanımlanıp fit(X, y) ile eğitilmiştir. Eğitim sonrası model, "xgb_final_model_saturasyon.model" dosyasına kaydedilerek tekrar eğitim gerektirmeden kullanılmak üzere saklanmıştır.

Başlangıçta satürasyon tahmini için regresyon modeli kullanılmıştır. Ancak, son aşamada sürekli tahminler belirli aralıklara ayrılarak sınıflandırmaya dönüştürülmüştür. Bu yaklaşım, model çıktılarının daha anlaşılır ve uygulanabilir olmasını sağlamıştır. Satürasyon değerleri, belirlenen eşiklere göre kategorik gruplara ayrılmış ve bu doğrultuda uygulanan adımlar;

Satürasyon tahmini için "ilce_encoded", "potasyum", "fosfor" ve "ph" değişkenleri kullanılmış; final_model ile X_new veri seti üzerinde tahminler alınmıştır. Elde edilen sürekli satürasyon tahminleri, 30, 50, 70 ve 110 eşiklerine göre "Kumlu", "Tınlı", "Killi tınlı", "Killi" ve "Ağır Killi" olarak kategorilere ayrılmıştır. Aynı sınıflandırma gerçek değerler için de yapılmış, böylece model çıktıları ile gerçek değerler doğrudan karşılaştırılmıştır. Doğruluk, hassasiyet, geri çağırma ve F1 skorları gibi metrikler classification_report ile raporlanmış; doğruluk skoru dört ondalık basamağa yuvarlanarak ekrana yazdırılmıştır. Ayrıca, model tahminleri ile gerçek değerlerin karşılaştırılması için comparison_df adlı bir tablo oluşturulmuş ve buradan rastgele

seçilen on satır ekrana yansıtılarak, modelin sınıflandırma başarımı örnek bazında görselleştirilmiştir şeklinde özetlenebilir.

Sonuç olarak, geliştirilen model satürasyon değerini başarılı bir şekilde tahmin etmiş ve sınıflandırma doğruluk oranı %77.07 olarak bulunmuştur. Benzer şekilde, topraktaki kireç ve organik madde miktarlarını tahmin etmek için XGBoost regresyon modelleri oluşturulmuş; ilce_encoded, potasyum, fosfor ve pH değişkenleriyle eğitim ve test kümeleri hazırlanmıştır. Hiperparametre optimizasyonu RandomizedSearchCV ile gerçekleştirilmiş, en iyi parametrelerle modeller eğitilip kaydedilmiştir. Özellik önem skorları grafikle görselleştirilmiş; tahmin edilen kireç ve organik madde değerleri kategorilere ayrılarak, modellerin doğruluk oranları sırasıyla %98.89 ve %93.35 olarak tespit edilmiştir. Sonuç olarak, mevcut ilçe, potasyum, fosfor ve pH bilgileri kullanılarak satürasyon, kireç ve organik madde değerlerinin hem sayısal tahminleri hem de sınıflandırmaları başarılı bir şekilde gerçekleştirilmiştir.

XGBoost ile yapılan tahminleme işlemlerinin ardından en yüksek doğruluk sonucunu elde etmek amacıyla Random forest, bagging, logistic regression ve decision tree algoritmaları ile de analiz yapılmıştır. Bu analiz sonuçlarını karşılaştıran tablo Çizelge 3.7 ile verilmiştir.

Çizelge 3.7. Algoritmaların doğruluk oranları

Hedef	**Random Forest**	**Bagging**	**Logistic Regression**	**Decision Tree**	**XGBoost**
Satürasyon	79.62	77.83	66.16	74.25	77.07
Kireç	97.87	95.98	81.45	93.7	98.89
Organik Madde	92.34	90.23	78.14	87.01	93.35

Tablodaki sonuçlar incelendiğinde, satürasyon tahmini için en yüksek doğruluk oranının %79.62 ile Random Forest algoritmasında elde edildiği görülmektedir. XGBoost, bu değişkende %77.07 ile ikinci sırada yer almıştır. Kireç ve organik madde değişkenlerinde ise XGBoost algoritması sırasıyla %98.89 ve %93.35 doğruluk oranlarıyla diğer tüm algoritmaların üzerinde bir performans göstermiştir. Özellikle kireç değişkeninde tüm algoritmalar yüksek doğruluk sağlamış olsa da XGBoost bu alanda açık farkla öne çıkmıştır. Logistic Regression ise üç hedef değişkenin tamamında en düşük doğruluk oranlarını üretmiş ve özellikle satürasyon ve organik madde tahminlerinde sınırlı başarı göstermiştir. Genel olarak, tablo farklı

algoritmaların her bir hedef değişkende farklı seviyelerde doğruluk sağladığını ortaya koymakta; ancak kireç ve organik madde tahmini açısından XGBoost'un üstünlüğünü açıkça göstermektedir.

3.2.3. Web tasarımı

Çalışmanın web tabanlı arayüzü, kullanıcıların makine öğrenmesi modelleri aracılığıyla tahmin edilen toprak verilerini gözlemleyebilmesi ve sonuçları etkileşimli şekilde değerlendirebilmesi amacıyla tasarlanmıştır. Kullanıcı arayüzünün geliştirilmesinde, React kütüphanesi temelli bir framework olan Next.js tercih edilmiştir. Vercel tarafından geliştirilen bu yapı, React'ın sunduğu bileşen tabanlı mimariyi desteklemekle birlikte; sunucu tarafı render desteği, performans iyileştirmeleri ve yönlendirme kolaylığı gibi ek avantajlar sunmaktadır. Next.js kullanımı sayesinde responsive (duyarlı) bir web sitesi oluşturulmuş ve farklı cihazlarda kullanıcı dostu bir deneyim sağlanmıştır.

Next.js framework'ünün bu projede tercih edilmesinin temel nedenleri arasında arama motoru optimizasyonunu desteklemesi, sayfa yükleme süresini azaltması ve kod yönetimini sadeleştirmesi yer almaktadır. Bu yapı sayesinde HTML içeriği, sunucu tarafında render edilerek daha hızlı erişim ve daha iyi SEO uyumu sağlanmıştır. Sayfaların statik olarak önceden oluşturulması, kullanıcı deneyiminde gözle görülür bir performans artışı yaratmıştır. Ayrıca, yalnızca ihtiyaç duyulan JavaScript dosyalarının yüklenmesini sağlayan kod bölme özelliği, uygulamanın daha hızlı yüklenmesine katkı sağlamıştır. Next.js aynı zamanda hem frontend hem de backend kodlarını aynı proje yapısı içinde barındırabilme olanağı sunmakta; bu sayede API uç noktaları tanımlanarak tam yığın (full-stack) web uygulamaları geliştirilebilmektedir. Dosya sistemi tabanlı yönlendirme yapısı, React bileşenlerini doğrudan sayfaya dönüştürerek yönlendirme süreçlerini otomatikleştirmiştir. Projede bu özelliklerden etkin biçimde faydalanılarak hem geliştirici verimliliği hem de sistem performansı artırılmıştır (Pati vd., 2025).

Çalışmanın Backend kısmı için Python tabanlı bir web framework olan FastAPI kullanılmıştır. Uygulamada oluşturulan predict_all fonksiyonu, FastAPI üzerinden tanımlanan bir POST metoduna sahip endpoint'e bağlanmıştır. Bu yapı sayesinde,

istemci tarafından endpoint'e gönderilen POST isteği alındığında predict_all fonksiyonu çalışmakta ve tahmin edilen sonuçları JSON formatında istemciye yanıt olarak döndürmektedir.

Sunucu tarafında geliştirilen kod yapısında, kullanıcıdan alınan ilçe, potasyum, fosfor ve pH verilerine dayanarak uygun ürün tahmini yapılmakta ve bu bilgiler predict_all adlı fonksiyona aktarılmaktadır. Web uygulaması, Python tabanlı FastAPI framework'ü kullanılarak geliştirilmiş; olası hata durumlarında kullanıcıya uygun yanıtlar dönebilmek amacıyla HTTPException sınıfı aracılığıyla hata yönetimi sağlanmıştır. Farklı sunucular arasında güvenli veri alışverişini mümkün kılmak için Middleware bileşenlerinden yararlanılmış, özellikle frontend ile backend yapılarının güvenli şekilde haberleşmesini sağlamak amacıyla CORS (Cross-Origin Resource Sharing) politikaları yapılandırılmıştır. Uygulama, app isimli bir FastAPI nesnesi üzerinden başlatılmış ve istemciden gelen verilerin türü (örneğin metin ya da sayısal değer) doğrulama kontrolleri ile denetlenmiştir. Bu veriler bir Python sözlüğü formatına dönüştürülerek tahmin fonksiyonuna yönlendirilmiş, ardından elde edilen sonuçlar JSON formatında dışa aktarılmıştır. Bu yapı sayesinde frontend uygulaması, sunucudan aldığı tahmin verilerini doğrudan ve güvenli biçimde kullanıcıya sunabilmektedir.

Kullanıcının karşısına çıkan web sayfası Şekil 3.4 ile istenilen veriler girildikten sonra döndürülen sonuçlar Şekil 3.5 ile gösterilmiştir.



Şekil 3.4. Kullanıcı ara yüzü

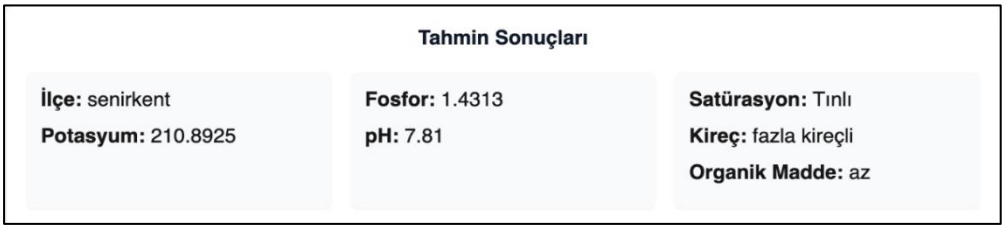

Şekil 3.5. Değer tahmin sonuçları

Geliştirilen web arayüzü aracılığıyla kullanıcılar, fosfor, potasyum ve pH değerlerini manuel olarak girebilmekte ve ilgili ilçeyi açılır liste (dropdown) üzerinden seçebilmektedir. Tüm bilgiler girildikten sonra "Tahmin Et" butonuna basıldığında, sistem kullanıcıyı otomatik olarak "Tahmin Sonuçları" sayfasına yönlendirmektedir. Bu sayfada, kullanıcının verdiği verilere dayanarak makine öğrenmesi modeli tarafından tahmin edilen satürasyon, kireç ve organik madde parametreleri sayısal değerlerle sunulmaktadır. Bu yapı sayesinde kullanıcılar, eriştikleri toprak yapısı hakkındaki bilgiler ile tarımsal karar destek de almış olacaktır.

4. BULGULAR

Bu çalışmada, tarımsal üretim süreçlerinde verimliliği artırmak ve çiftçilerin karar alma mekanizmalarını desteklemek amacıyla makine öğrenmesi temelli bir karar destek sistemi geliştirilmiştir. Araştırmanın birinci aşamasında, topraktan alınan örnekler doğrultusunda pH, potasyum ve fosfor gibi temel parametrelerin yanı sıra ilçe bilgisi kullanılarak; satürasyon, kireç ve organik madde düzeylerinin tahmin edilmesine yönelik regresyon modelleri geliştirilmiştir. Bu modellerde XGBoost, random forest, bagging, logistic regression ve decision tree algoritmaları karşılaştırılmış en yüksek doğruluk oranları satürasyon; %77.07, kireç; %98.89, organik madde; %93.35 ile XGBoost algoritması olmuştur. RandomizedSearchCV ile hiperparametre optimizasyonları gerçekleştirilmiş ve RMSE gibi hata metrikleri kullanılarak performans değerlendirmeleri yapılmıştır. Tahmin sonuçları sınıflandırılarak kullanıcıların daha anlamlı yorumlar yapabilmesi hedeflenmiş ve sınıf bazlı doğruluk, F1 skoru gibi istatistiksel metriklerle başarım düzeyleri ortaya konmuştur. Karşılaştırmaları yapılarak en yüksek doğruluk oranının bulunmasının hedeflendiği çalışmada XGBoost, random forest, bagging, logistic regression ve decision tree algoritmalarının doğruluk karşılaştırılması Çizelge 4.1 ile gösterilmiştir.

Çizelge 4.1. Veri seti ile doğruluk karşılaştırması

Algoritma	**Satürasyon (%)**	**Kireç (%)**	**Organik Madde (%)**
XGBoost	82.3	99.0	94.0
Random Forest	80.8	98.5	92.0
Bagging	80.4	96.8	89.0
Decision Tree	75.3	95.0	86.0
Logistic Regression	65.2	85.0	80.0

Farklı makine öğrenmesi algoritmalarının üç temel değişken üzerindeki tahmin performansları incelendiğinde, XGBoost algoritmasının satürasyon (%82.3), kireç (%99.0) ve organik madde (%94.0) değişkenlerinde en yüksek doğruluk oranlarını sağladığı belirlenmiştir. Random Forest, XGBoost'un ardından en yüksek doğruluk değerlerine ulaşmıştır (satürasyon: %80.8, kireç: %98.5, organik madde: %92.0). Bagging algoritması ise tüm değişkenlerde Random Forest'a göre daha düşük performans göstermiştir**.** Decision Tree ve Logistic Regression algoritmalarında ise doğruluk oranlarında ciddi bir azalma gözlenmiştir; özellikle Logistic Regression algoritması, satürasyon için %65.2, kireç için %85.0 ve organik madde için %80.0 ile en düşük doğruluk değerlerini üretmiştir. Elde edilen bu bulgular, her üç değişkenin

tahmininde de en optimal sonuçların XGBoost algoritmasıyla elde edildiğini açıkça göstermektedir. Çalışmada kullanılan algoritmaların satürasyon, kireç ve organik madde sınıflandırmasındaki temel başarı metrikleri Çizelge 4.2 ile gösterilmiştir.

Çizelge 4.2. Temel başarı metrikleri

	Satürasyon			Kireç			Organik Madde		
Algoritma	**Precision**	**Recall**	**F1 Score**	**Precision**	**Recall**	**F1 Score**	**Precision**	**Recall**	**F1 Score**
Random Forest	0.790	0.566	0.620	0.705	0.676	0.689	0.814	0.755	0.779
Bagging	0.774	0.578	0.635	0.704	0.697	0.700	0.895	0.889	0.892
Decision Tree	0.499	0.532	0.511	0.703	0.693	0.697	0.872	0.876	0.874
Logistic Regression	0.327	0.334	0.330	0.705	0.705	0.705	0.276	0.257	0.229
XGBoost	0.690	0.660	0.670	0.960	0.950	0.955	0.800	0.780	0.785

Bulgular, değişken bazında algoritmalar arasında anlamlı performans farklılıkları bulunduğuna işaret etmektedir. Özellikle kireç değişkeni açısından değerlendirildiğinde, XGBoost algoritması hem precision (0.960) hem de recall (0.950) değerlerinde gösterdiği üstün başarı ile öne çıkmakta, 0.955'lik F1 skoru ile yüksek doğruluk ve istikrar sağlamaktadır. Satürasyon değişkeninde de XGBoost, en yüksek F1 skoruna (0.670) ulaşmış; Bagging ve Random Forest algoritmaları ise benzer düzeyde kabul edilebilir başarı oranları sergilemiştir. Buna karşılık, Logistic Regression algoritmasının tüm değişkenler açısından anlamlı şekilde daha düşük precision ve F1 skorları elde ettiği görülmektedir. Organik madde değişkeninde ise en başarılı sonuç Bagging algoritmasında gözlemlenmiş (F1 skoru: 0.892), Decision Tree ve Random Forest da bu başarıya yakın düzeyde performans göstermiştir. Elde edilen bu veriler, özellikle XGBoost ve Bagging gibi topluluk algoritmalarının yüksek boyutlu ve karmaşık veri setlerinde klasik algoritmalara kıyasla daha üstün sınıflandırma başarısı ortaya koyduğunu göstermektedir. Sonuç olarak, XGBoost algoritması genel olarak en tutarlı ve yüksek performansa sahip model olarak öne çıkarken, Logistic Regression'ın karmaşık yapıda yetersiz kaldığı tespit edilmiştir.

Tahminleme sonuçlarına göre algoritmaların satürasyon değeri için sınıf performansları Çizelge 4.3'te XGBoost sınıf performansı, Çizelge 4.4'te Random Forest sınıf performansı, Çizelge 4.5'te Bagging sınıf performansı, Çizelge 4.6'te

Decision Tree sınıf performansı, Çizelge 4.7'te Logistic Regression sınıf performansı ile verilmiştir.

Çizelge 4.3. XGBoost sınıf performansı (satürasyon)

class	precision	recall	f1-score
0 (ağır killi)	0.902	0.315	0.454
1 (killi)	0.815	0.862	0.837
2 (killi tınlı)	0.728	0.488	0.578
3 (tınlı)	0.843	0.834	0.835

Çizelge 4.4. Random Forest sınıf performansı (satürasyon)

class	precision	recall	f1-score
0 (ağır killi)	0.875	0.218	0.35
1 (killi)	0.795	0.840	0.817
2 (killi tınlı)	0.666	0.4	0.5
3 (tınlı)	0.823	0.803	0.813

Çizelge 4.5. Bagging sınıf performansı (satürasyon)

class	precision	recall	f1-score
0 (ağır killi)	0.818	0.281	0.418
1 (killi)	0.791	0.841	0.816
2 (killi tınlı)	0.666	0.4	0.5
3 (tınlı)	0.819	0.790	0.804

Çizelge 4.6. Decision Tree sınıf performansı (satürasyon)

class	precision	recall	f1-score
0 (ağır killi)	0.361	0.406	0.382
1 (killi)	0.760	0.769	0.764
2 (killi tınlı)	0.1	0.2	0.133
3 (tınlı)	0.773	0.754	0.763

Çizelge 4.7. Logistic Regression sınıf performansı (satürasyon)

class	precision	recall	f1-score
0 (ağır killi)	0.0	0.0	0.0
1 (killi)	0.645	0.708	0.675
2 (killi tınlı)	0.0	0.0	0.0
3 (tınlı)	0.660	0.626	0.643

Satürasyon sınıf performansları açısından Logistic Regression algoritmasının, yalnızca "killi" ve "tınlı" sınıflarında anlamlı bir tahmin başarısı gösterdiği, ancak

“ağır killi” ve “killi tınlı” sınıflarında tamamen yetersiz kaldığı görülmektedir. Decision Tree algoritması ise “killi” ve “tınlı” sınıflarında yüksek precision, recall ve F1 skoru üretirken, “ağır killi” ve özellikle “killi tınlı” sınıflarında performansı belirgin şekilde düşmektedir. Bagging algoritmasında, “killi” ve “tınlı” sınıflarında yüksek F1 skorları (0.816 ve 0.804) elde edilmiş, “ağır killi” ve “killi tınlı” sınıflarında ise kısmi bir doğruluk sağlanabilmiştir. Random Forest algoritması, “killi” ve “tınlı” gruplarında benzer şekilde yüksek başarı göstermiş, “ağır killi” ve “killi tınlı” gruplarında ise düşük recall değerleri nedeniyle toplam F1 skorları sınırlı kalmıştır. XGBoost algoritması ise, tüm sınıflarda görece daha dengeli bir performans sergilemiş; özellikle “killi” (F1: 0.837) ve “tınlı” (F1: 0.835) sınıflarında en yüksek F1 skorlarına ulaşmıştır. “Ağır killi” ve “killi tınlı” gruplarında ise diğer algoritmalara kıyasla daha yüksek precision ve F1 skorları elde edilmiştir.

Sınıf bazlı performanslar karşılaştırıldığında, genel olarak ensemble yöntemleri olan XGBoost, Bagging ve Random Forest’ın “killi” ve “tınlı” gruplarında istikrarlı ve yüksek doğrulukta sonuçlar ürettiği, klasik yöntemlerin (özellikle Logistic Regression) ise çok sınıflı dengesiz veri dağılımı karşısında ciddi anlamda yetersiz kaldığı anlaşılmaktadır. XGBoost, sadece ortalama başarı açısından değil, aynı zamanda dengesiz sınıf dağılımına rağmen tüm sınıflarda tutarlı sonuçlar vermesiyle öne çıkmaktadır. Bununla birlikte, “ağır killi” ve “killi tınlı” gibi düşük örnekleme sahip sınıflarda tüm modellerde genel olarak düşük recall ve F1 skorları dikkat çekmektedir; bu da verinin dağılımından kaynaklı olarak modellerin bu grupları doğru sınıflandırmakta zorlandığını göstermektedir. Sonuç olarak, satürasyon tahmininde en yüksek ve dengeli performans XGBoost ile elde edilirken, Bagging ve Random Forest algoritmaları da belirli sınıflarda yüksek başarı sağlamış, Logistic Regression ise çok sınıflı veri yapısında anlamlı bir tahmin yeteneği gösterememiştir.

Tahminleme sonuçlarına göre algoritmaların kireç değeri için sınıf performansları Çizelge 4.8’te XGBoost sınıf performansı, Çizelge 4.9’te Random Forest sınıf performansı, Çizelge 4.10’te Bagging sınıf performansı, Çizelge 4.11’te Decision Tree sınıf performansı, Çizelge 4.12’te Logistic Regression sınıf performansı ile verilmiştir.

Çizelge 4.8. XGBoost sınıf performansı (kireç)

class	precision	recall	f1-score
0 (az kireçli)	0.85	0.60	0.70
1 (kireçli)	0.94	0.88	0.91
2 (çok kireçli)	0.995	0.995	0.995

Çizelge 4.9. Random Forest sınıf performansı (kireç)

class	precision	recall	f1-score
0 (çok az)	0.0	0.0	0.0
1 (az kireçli)	1.0	0.785	0.88
2 (orta kireçli)	0.984	0.965	0.974
3 (kireçli)	0.967	0.994	0.981
4 (çok kireçli)	0.989	0.991	0.991

Çizelge 4.10. Bagging sınıf performansı (kireç)

class	precision	recall	f1-score
0 (çok az)	0.0	0.0	0.0
1 (az kireçli)	1.0	0.928	0.963
2 (orta kireçli)	0.973	0.977	0.975
3 (kireçli)	0.967	0.994	0.981
4 (çok kireçli)	0.993	0.980	0.987

Çizelge 4.11. Decision Tree sınıf performansı (kireç)

class	precision	recall	f1-score
0 (çok az)	0.0	0.0	0.0
1 (az kireçli)	1.0	0.928	0.963
2 (orta kireçli)	0.976	0.962	0.969
3 (kireçli)	0.967	0.978	0.973
4 (çok kireçli)	0.987	0.983	0.985

Çizelge 4.12. Logistic Regression sınıf performansı (kireç)

class	precision	recall	f1-score
0 (çok az)	0.0	0.0	0.0
1 (az kireçli)	1.0	1.0	1.0
2 (orta kireçli)	0.977	0.973	0.975
3 (kireçli)	0.978	0.978	0.978
4 (çok kireçli)	0.9839	0.989	0.986

Logistic Regression algoritmasının kireç sınıfı tahmin performansına bakıldığında, modelin yalnızca “0 (çok az kireçli)” sınıfında hiçbir başarı gösteremediği; precision, recall ve F1-skoru değerlerinin sıfır olduğu görülmektedir. Buna karşılık, “1”, “2”, “3” ve “4” numaralı sınıflarda precision, recall ve F1-skoru oranları oldukça yüksektir ve model bu sınıfları başarıyla tahmin etmiştir. Decision Tree modeli için de benzer bir durum mevcuttur: “0 (çok az kireçli)” sınıfında tamamen başarısız olunurken, özellikle “az kireçli”, “orta kireçli”, “kireçli” ve “çok kireçli” sınıflarında modelin oldukça yüksek ve dengeli sonuçlar ürettiği (F1-skorları 0.963–0.985 arasında) izlenmektedir. Bagging algoritması da “çok az kireçli” sınıfında başarı elde edememiş, bunun dışında kalan tüm sınıflarda F1-skorlarının 0.963 ile 0.987 arasında değiştiği, yani modelin genellikle üst kireç sınıflarında güçlü bir sınıflandırma başarısı sergilediği görülmüştür. Random Forest algoritmasında da durum benzerdir: “çok az kireçli” sınıfında sıfır başarı söz konusuyken, diğer dört sınıfta precision, recall ve F1-skoru yüksek düzeyde gerçekleşmiştir. Son olarak XGBoost algoritması, daha sadeleştirilmiş üçlü bir sınıflandırma ile (“az kireçli”, “kireçli”, “çok kireçli”) tüm sınıflarda yüksek başarıya ulaşmış, özellikle “çok kireçli” grubunda F1-skoru 0.995 ile neredeyse kusursuz bir tahmin performansı sergilemiştir.

Tüm modellerin kireç değişkeni için elde edilen sınıf bazlı performansları karşılaştırıldığında, özellikle “çok az kireçli” sınıfında hiçbir algoritmanın anlamlı bir başarı sağlayamadığı, diğer tüm sınıflarda ise yüksek doğruluk ve tutarlılık gözlemlendiği ortaya çıkmaktadır. Logistic Regression modeli, “çok az kireçli” sınıfı dışında kalan tüm sınıflarda başarılı sonuçlar üretmiş olsa da bu sınıfı tamamen göz ardı etmesi modelin genel performans dengesi açısından zayıflık göstermektedir. Decision Tree, Bagging ve Random Forest algoritmaları da benzer biçimde nadir veya dengesiz dağılıma sahip sınıfta başarısız olurken, kalan sınıflarda yüksek doğruluk, duyarlılık ve F1-skorları elde etmişlerdir. XGBoost algoritması ise, veri setinin karmaşıklığını azaltmak adına üçlü sınıflandırmaya gitmiş ve bu sınıfların tamamında yüksek başarı sağlamıştır; özellikle “çok kireçli” sınıfında neredeyse kusursuz sonuçlar elde edilmiştir. Sonuç olarak, dengesiz veri yapısının hâkim olduğu “çok az kireçli” gibi nadir sınıflar tüm algoritmalar için belirgin bir zorluk oluştururken, ensemble yöntemler (özellikle XGBoost) genel doğruluk, duyarlılık ve tutarlılık açısından klasik yöntemlere kıyasla daha istikrarlı ve güvenilir sonuçlar sunmaktadır. Bu bulgular, dengesiz sınıf dağılımlarında model başarısını değerlendirirken sadece

genel başarı oranlarına değil, sınıf bazlı performanslara da dikkat edilmesi gerektiğini net biçimde ortaya koymaktadır.

Tahminleme sonuçlarına göre algoritmaların organik madde değeri için sınıf performansları Çizelge 4.13'te XGBoost sınıf performansı, Çizelge 4.14'te Random Forest sınıf performansı, Çizelge 4.15'te Bagging sınıf performansı, Çizelge 4.16'te Decision Tree sınıf performansı, Çizelge 4.17'te Logistic Regression sınıf performansı ile verilmiştir.

Çizelge 4.13. XGBoost sınıf performansı (organik madde)

class	precision	recall	f1-score
0	0.925	0.851	0.883
1	0.937	0.952	0.945
2	0.865	0.90	0.887

Çizelge 4.14. Random Forest sınıf performansı (organik madde)

class	precision	recall	f1-score
0	0.819	0.903	0.859
1	0.697	0.526	0.6
2	0.712	0.728	0.719
3	0.877	0.672	0.761
4	0.963	0.946	0.954

Çizelge 4.15. Bagging sınıf performansı (organik madde)

class	precision	recall	f1-score
0	0.925	0.953	0.938
1	0.819	0.754	0.785
2	0.887	0.897	0.892
3	0.862	0.875	0.868
4	0.981	0.966	0.973

Çizelge 4.16. Decision Tree sınıf performansı (organik madde)

class	precision	recall	f1-score
0	0.917	0.932	0.924
1	0.767	0.754	0.761
2	0.883	0.867	0.875
3	0.821	0.859	0.839
4	0.971	0.966	0.968

Çizelge 4.17. Logistic Regression sınıf performansı (organik madde)

class	precision	recall	f1-score
0	0.377	0.215	0.273
1	0.276	0.114	0.161
2	0.258	0.058	0.095
3	0.0	0.0	0.0
4	0.469	0.898	0.616

Her bir modelin organik madde sınıf performansları incelendiğinde; XGBoost algoritmasının üç sınıfa (çok az, az, orta-yüksek) ayırdığı organik madde tahminlerinde tüm sınıflarda yüksek precision, recall ve F1-skoru değerlerine ulaştığı görülmektedir. Özellikle "az" sınıfında F1-skorunun 0.945'e kadar çıktığı, diğer sınıflarda da bu oranın 0.883 ve 0.887 gibi yüksek seviyelerde olduğu dikkat çekmektedir. Random Forest modelinde ise beş farklı sınıfta değerlendirilen organik madde tahmininde "4" numaralı sınıfta (en yüksek sınıf) modelin F1-skoru 0.954 ile en yüksek değere ulaşmış, "0" ve "1" numaralı sınıflarda ise F1-skorları anlamlı şekilde daha düşük kalmıştır. Bagging algoritmasında, "0" ve "4" numaralı sınıflarda F1-skorları oldukça yüksekken (sırasıyla 0.938 ve 0.973), diğer sınıflarda bu oranın biraz daha düşük ancak yine de tatmin edici olduğu görülmektedir. Decision Tree modeli de benzer biçimde "0" ve "4" numaralı sınıflarda oldukça yüksek F1-skorları (0.924 ve 0.968) üretmiş, diğer sınıflarda ise F1-skorları 0.761 ile 0.875 arasında kalmıştır. Buna karşılık, Logistic Regression algoritması bütün sınıflarda belirgin şekilde düşük performans göstermiş, özellikle "2" ve "3" numaralı sınıflarda modelin neredeyse hiç ayırt edici bir tahmin başarısı sergileyemediği, yalnızca "4" numaralı sınıfta görece daha yüksek bir başarıya ulaştığı gözlenmiştir.

Genel karşılaştırma yapıldığında, ensemble (topluluk) tabanlı yöntemler olan XGBoost, Bagging ve Random Forest algoritmalarının, organik madde tahmininde hem genel doğruluk hem de sınıf bazında yüksek ve dengeli F1-skorlarına ulaştığı açıkça ortaya çıkmaktadır. Özellikle XGBoost ve Bagging algoritmaları, tüm sınıflarda tutarlı ve yüksek doğruluk seviyeleri ile öne çıkarken, Decision Tree modeli de üst sınıflarda benzer şekilde yüksek başarı sağlamıştır. Random Forest ise özellikle

en yüksek organik madde sınıfında dikkat çekici bir başarıya sahipken, düşük ve orta sınıflarda daha sınırlı kalmıştır. Logistic Regression ise çok sınıflı ve dengesiz dağılım gösteren veri setinde oldukça yetersiz kalmış, çoğu sınıfta modelin ayırt edici gücü son derece düşük seviyede kalmıştır. Bu bulgular, karmaşık ve çok sınıflı organik madde tahmin problemlerinde klasik yöntemlerin yetersizliğine ve ensemble yöntemlerin sağladığı avantajlara güçlü bir kanıt oluşturmaktadır.

Makine öğrenmesi algoritmalarının satürasyon, kireç ve organik madde değişkenlerini tahmin etmedeki doğruluk oranları karşılaştırmalı olarak Şekil 4.1 ile gösterilmektedir.

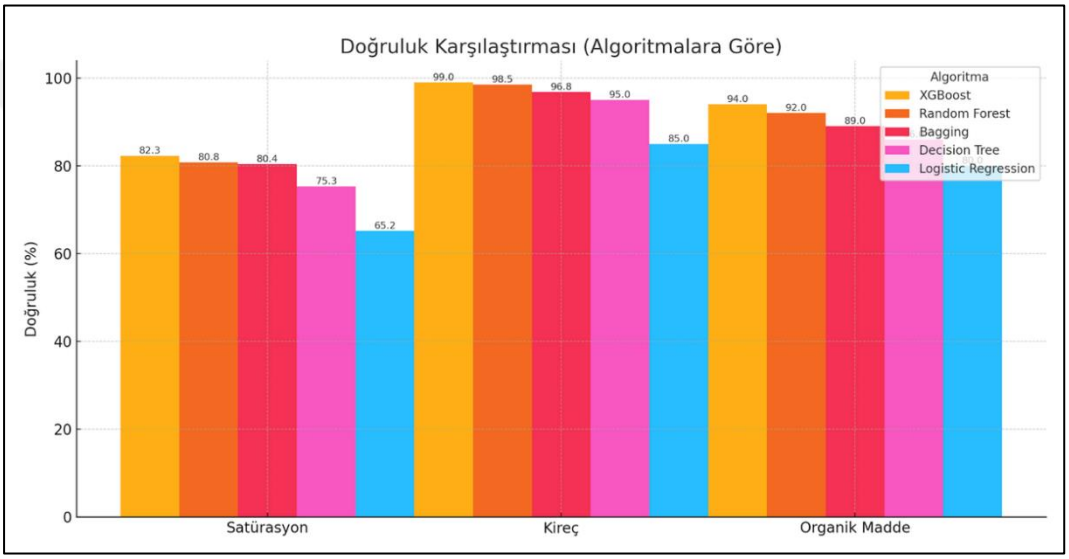

Şekil 4.1. Algoritmaların doğruluk oranları karşılaştırılması

Grafik, tüm değişkenlerde XGBoost algoritmasının en yüksek doğruluk oranlarına ulaştığını açıkça göstermektedir. Özellikle kireç değişkeninde XGBoost'un doğruluğu %99 ile neredeyse kusursuz bir tahmin başarısı ortaya koyarken, bu başarıya en yakın algoritmalar Random Forest (%98.5) ve Bagging (%96.8) olmuştur. Satürasyon ve organik madde değişkenlerinde de XGBoost doğruluk oranı bakımından lider konumda olup (%82.3 ve %94.0), onu Random Forest, Bagging ve Decision Tree algoritmaları izlemektedir.

Tüm algoritmalar açısından değerlendirildiğinde, Decision Tree ve Logistic Regression modellerinin her üç değişkende de diğer yöntemlere göre daha düşük doğruluk oranlarına sahip olduğu dikkat çekmektedir. Logistic Regression özellikle satürasyon ve organik madde değişkenlerinde en düşük doğruluk yüzdelerine sahip

algoritma olarak öne çıkmaktadır. Bagging ve Random Forest ise genel olarak yüksek doğruluk oranlarıyla XGBoost'un ardından gelmektedir. Elde edilen bu sonuçlar, karmaşık ve çok sınıflı tahmin problemlerinde ensemble tabanlı yöntemlerin (özellikle XGBoost, Random Forest ve Bagging) klasik yöntemlere kıyasla çok daha güvenilir ve yüksek performans sunduğunu açıkça ortaya koymaktadır.

Sonuç olarak, XGBoost algoritması her üç hedef değişkende de en yüksek doğruluk oranını sağlayarak en başarılı model olarak öne çıkmış, diğer ensemble yöntemler de benzer şekilde yüksek performans sergilemiştir. Klasik modeller ise, özellikle veri setinin karmaşıklığı ve dengesiz sınıf dağılımı karşısında yetersiz kalmıştır. Doğruluk oranı en yüksek olan üç algoritmanın (XGBoost, Random Forest ve Bagging) organik madde, kireç ve satürasyon tahminlerindeki sınıflandırma performansları sırasıyla Şekil 4.2, Şekil 4.3 ve Şekil 4.4 ile gösterilmiştir.

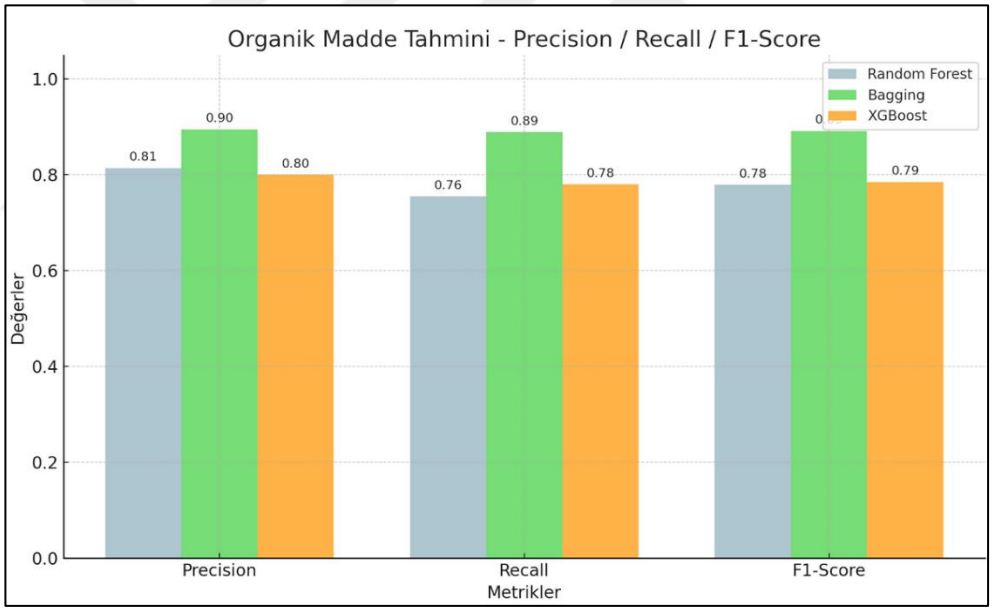

Şekil 4.2. Organik madde değerinin sınıflandırma performansı

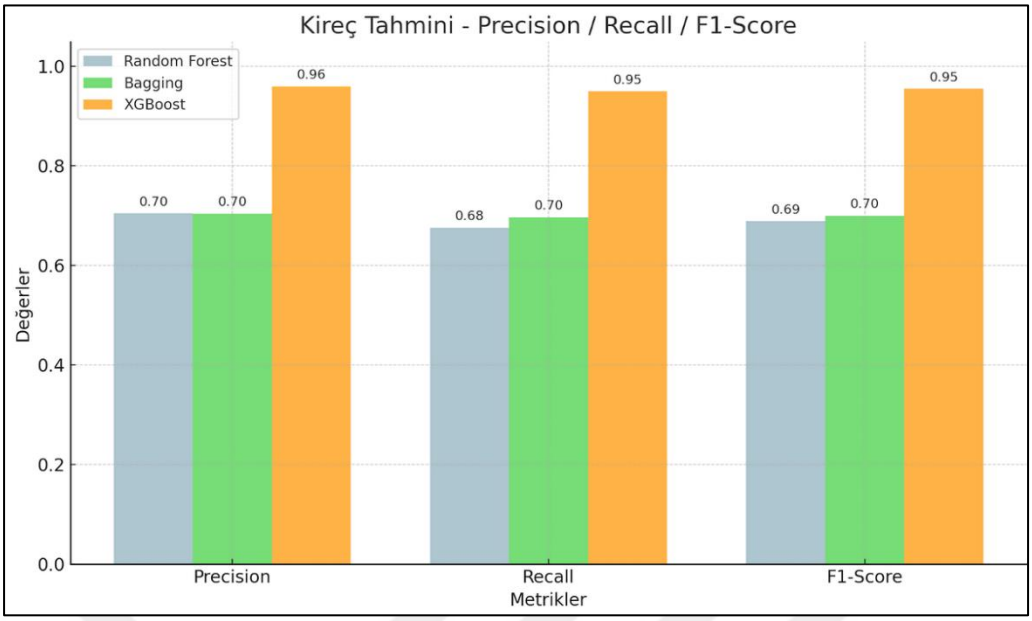

Şekil 4.3. Kireç değerinin sınıflandırma performansı

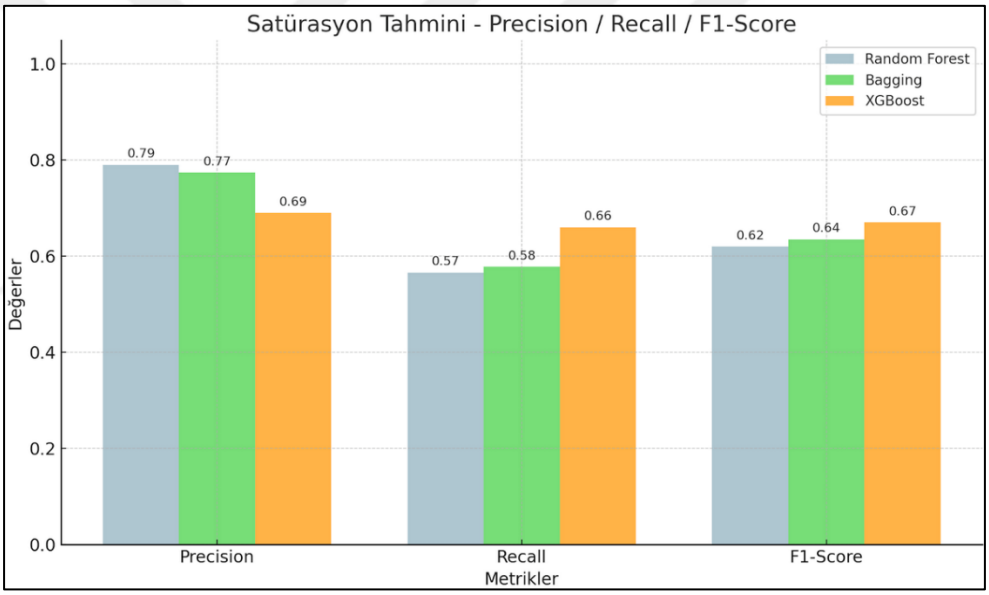

Şekil 4.4. Satürasyon değerinin sınıflandırma performansı

Temel metrikler (precision, recall ve F1-score) üzerinden karşılaştırıldığında, tüm değişkenlerde XGBoost'un genel olarak en yüksek veya rakiplerine çok yakın F1-score değerleriyle öne çıktığı görülmektedir. Özellikle kireç tahmininde XGBoost, precision (%96), recall (%95) ve F1-score (%95) ile rakiplerine anlamlı bir üstünlük sağlamaktadır; Random Forest ve Bagging algoritmaları bu değişkende belirgin biçimde daha düşük performans göstermiştir. Organik madde tahmininde ise Bagging algoritması precision (%90), recall (%89) ve F1-score (%89) ile öne çıkarken, XGBoost da bu metriklerde benzer yüksek değerlere ulaşmıştır (özellikle F1-score: %79). Satürasyon tahmininde ise üç algoritmanın başarı oranları birbirine yakın

seyretmekle birlikte, XGBoost'un recall ve F1-score metriklerinde (sırasıyla %66 ve %67) Bagging ve Random Forest'a göre bir miktar daha iyi sonuçlar ürettiği gözlemlenmektedir. Genel olarak, üç algoritma arasında ensemble tabanlı yaklaşımların (özellikle XGBoost) tüm değişkenlerde yüksek doğruluk, dengeli hassasiyet ve genel başarıya sahip olduğu, ancak organik madde tahmininde Bagging'in de güçlü bir alternatif olarak öne çıktığı anlaşılmaktadır. Bu bulgular, XGBoost'un kompleks tarımsal veri setlerinde istikrarlı ve üstün bir modelleme yeteneği sunduğunu açıkça ortaya koymaktadır.

5. TARTIŞMA VE SONUÇ

Bu çalışmada, toprak analiz verilerine dayalı olarak tarımsal karar destek sürecine katkı sağlayacak bir yapay zekâ tabanlı tahmin sistemi geliştirilmiştir. Toprak özelliklerinin (satürasyon, kireç ve organik madde) sınıflandırılmasına yönelik olarak XGBoost, Random Forest, Bagging, Decision Tree ve Logistic Regression gibi farklı makine öğrenmesi algoritmalarının performansları çok boyutlu metriklerle karşılaştırılmıştır. Elde edilen bulgular, kullanılan veri setinin yapısına ve hedef değişkenlerin sınıf dağılımına bağlı olarak, modeller arasında belirgin performans farklılıkları olduğunu ortaya koymaktadır. Bu farklar, her bir parametrenin tahmin edilebilirliğindeki doğasal karmaşıklığın yanı sıra, çalışmada kullanılan verilerin miktar ve dağılım farklılıklarından da kaynaklanmaktadır. Özellikle nadir görülen sınıflarda model başarısının düşük kalması, veri setindeki dengesizliğin doğrudan etkisidir.

Bu noktada özellikle vurgulanması gereken bir husus, ürün tahmin modeline temel oluşturan veri kümesinin doğasıdır. Veri seti, Isparta İl Özel İdaresi tarafından sağlanan, çiftçilerin kendi arazilerine ekmeyi tercih ettikleri ürünlere ilişkin analiz sonuçlarından oluşmaktadır. Bu durum, modelin öğrenme sürecini doğrudan etkilemektedir. Böyle bir yapay zekâ sisteminin tahmin kapasitesi, yalnızca bilimsel-tarımsal uygunlukla değil, aynı zamanda çiftçi davranışlarının öğrenilmiş örüntüleriyle de sınırlıdır.

Analiz sonuçlarına göre, XGBoost algoritması genel doğruluk, precision, recall ve F1-score gibi temel metrikler bakımından üç değişkenin tamamında üstün bir başarı sergilemiştir. Özellikle kireç değişkeninde %99 doğruluk oranı ve F1-score'unun %95 düzeyinde olması, modelin karmaşık ve çok sınıflı tahmin problemlerinde dahi yüksek genelleme kapasitesine sahip olduğunu göstermektedir. Satürasyon ve organik madde tahminlerinde de XGBoost, rakip algoritmalara kıyasla daha yüksek veya benzer doğruluk ve tutarlılıkla öne çıkmıştır. Bagging ve Random Forest modelleri ise, özellikle organik madde değişkeninde yüksek F1-score ve doğruluk değerleriyle XGBoost'a yakın sonuçlar üretmiş, ancak özellikle dengesiz ya da nadir görülen sınıflarda performans kaybı yaşamıştır. Decision Tree algoritması ise genel olarak üst sınıflarda kabul edilebilir sonuçlar üretse de modelin genel başarısı topluluk

(ensemble) yöntemlerine göre daha düşük kalmıştır. Logistic Regression algoritması ise, çok sınıflı ve dengesiz veri setinde çoğu zaman düşük precision, recall ve F1-score değerleriyle, problem üzerinde yetersiz bir modelleme kapasitesine sahip olduğunu ortaya koymuştur.

Sınıf bazlı analizler, özellikle "çok az kireçli" ve düşük organik madde grubu gibi nadir veya dengesiz dağılıma sahip sınıflarda, klasik algoritmaların anlamlı bir tahmin başarısı gösteremediğini ortaya koyarken; topluluk temelli yöntemlerin (özellikle XGBoost ve Bagging) hem yüksek başarı oranı hem de sınıflar arası tutarlılık açısından daha güvenilir sonuçlar ürettiği görülmüştür. Grafiksel karşılaştırmalar da XGBoost'un başta kireç olmak üzere, tüm hedef değişkenlerde en yüksek F1-score ve doğruluk oranlarına ulaştığını açıkça göstermektedir. Özellikle tarımsal veri setlerinde, hedef değişkenlerin çok sınıflı ve dengesiz yapısı göz önüne alındığında, ensemble yaklaşımların klasik yöntemlere kıyasla daha avantajlı ve genellenebilir olduğu bu çalışma ile bir kez daha ortaya konmuştur.

Sonuç olarak, elde edilen bulgular doğrultusunda, XGBoost algoritmasının toprak özelliklerinin sınıflandırılması ve tahmini için hem doğruluk hem de sınıf bazında istikrarlı ve yüksek performans sunması nedeniyle tercih edilmesi önerilmektedir. Model seçiminde ise veri setinin yapısı, hedef değişkenlerin dağılımı ve sınıf dengesizliği gibi unsurların dikkate alınmasının hem bilimsel hem de pratik açıdan kritik öneme sahip olduğu bu çalışma ile vurgulanmıştır. Gelecekte yapılacak çalışmalarda, dengesiz sınıf problemlerinin azaltılması amacıyla farklı örnekleme tekniklerinin ve gelişmiş optimizasyon yöntemlerinin denenmesi, model performansının daha da iyileştirilmesi açısından faydalı olacaktır. Ayrıca daha dengeli, kapsamlı ve amaca özel hazırlanmış veri setleriyle bu tür sistemlerin doğruluğunun ve güvenilirliğinin önemli ölçüde artırılabileceği öngörülmektedir.

KAYNAKÇA

Afzal, H., Amjad, M., Raza, A., Munir, K., Gracia Villar, S., Alonso Dzul Lopez, L., & Ashraf, I. (2025). Incorporating soil information with machine learning for crop recommendation to improve agricultural output. *Scientific Reports, 15*, Article 8560. https://doi.org/10.1038/s41598-025-88676-z

Akın, M., & Akın, G. (2007). Suyun önemi, Türkiye'de su potansiyeli, su havzaları ve su kirliliği. *Ankara Üniversitesi Dil ve Tarih-Coğrafya Fakültesi Dergisi*, *47*(2), 105–118.

Aksoy, B., Halis, H. D., & Salman, O. K. M. (2020). Elma bitkisindeki hastalıkların yapay zekâ yöntemleri ile tespiti ve yapay zekâ yöntemlerinin performanslarının karşılaştırılması. *International Journal of Engineering and Innovative Research, 2*(3), 194–210. https://doi.org/10.47933/ijeir.772514

Aksu, L. (2011). Dünya'da ve Türkiye'de nüfus analizleri. *Istanbul Journal of Sociological Studies, 25*, 219–309.

Alam, S., Cartledge, C. L., & Nelson, M. L. (2014). Support for various HTTP methods on the web. https://arxiv.org/abs/1405.2330. (Son erişim tarihi: 15 Haziran 2025)

Aldağ, M. C., Eker, B., & Akdoğan Eker, A. (2018). Tarım makinaları imalatında yapay zekâ uygulamaları. International refereed conference on engineering and sciences, İstanbul, Türkiye. https://www.researchgate.net/publication/329442922. (Son erişim tarihi: 15 Haziran 2025)

Altıntaş, Ç. (2025). Toprak kalite sensörü nedir? Esular. https://esular.com/toprak-kalite-sensoru-nedir. (Son erişim tarihi: 15 Haziran 2025)

Aras, İ. (2006). Damla sulama yöntemi. *Tarla Bitkileri Merkez Araştırma Enstitüsü Dergisi, 15*(1–2), 49–60.

Atalay, M., & Çelik, E. (2017). Büyük veri analizinde yapay zekâ ve makine öğrenmesi uygulamaları. *Mehmet Akif Ersoy Üniversitesi Sosyal Bilimler Enstitüsü Dergisi, 9*(22), 155–172. https://doi.org/10.20875/makusobed.309727

Aydın Eryılmaz, G., & Kılıç, O. (2018). Türkiye'de sürdürülebilir tarım ve iyi tarım uygulamaları. *KSÜ Tarım ve Doğa Dergisi, 21*(4), 624–631. https://doi.org/10.18016/ksudobil.345137

Aydın Eryılmaz, G., Kılıç, O., & Boz, İ. (2019). Türkiye'de organik tarım ve iyi tarım uygulamalarının ekonomik, sosyal ve çevresel sürdürülebilirlik açısından değerlendirilmesi. *Yüzüncü Yıl Üniversitesi Tarım Bilimleri Dergisi, 29*(2), 352–361. https://doi.org/10.29133/yyutbd.446002

Aylak, B. L., Oral, O., & Yazıcı, K. (2021). Yapay zeka ve makine öğrenmesi tekniklerinin lojistik sektöründe kullanımı. *El-Cezerî Fen ve Mühendislik Dergisi, 8*(1), 74–93. https://doi.org/10.31202/ecjse.776314

Baran, M. F., Bellitürk, K., & Çelik, A. (2021). *Türkiye'de Sürdürülebilir Tarım Uygulamaları: Zorluklar ve potansiyeller*. İKSAD Publishing House.

Bayar, R. (2018). Türkiye'de nüfus gelişimi. *International Journal of Geography and Geography Education, 38*, 247–266.

Baydar, H. (2015). Yeni yeşil devrimlere, yeni Norman Borlaug'lara ihtiyacımız var. *Türkiye Tohumcular Birliği Dergisi*, (Ocak), 8–11.

Bayrakçı, H. C., Çiçekdemir, R. S., & Özkahraman, M. (2021). Tarım arazilerinde harcanan su miktarını yapay zekâ teknikleri kullanarak belirlenmesi. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi, 9,* 237–250. https://doi.org/10.29130/dubited.1015690

Bilir, S. (2010). *Isparta İlinde Gülcülük ve Ekonomik Önemi.* (Yüksek Lisans Tezi, İstanbul Üniversitesi Sosyal Bilimler Enstitüsü)

Bommireddy, D. R. (2024). *Recommendation System Using Machine Learning For Fertilizer Prediction.* (Master's thesis, California State University, San Bernardino)

Bondre, D. A., & Mahagaonkar, S. (2019). Prediction of crop yield and fertilizer recommendation using machine learning algorithms. *International Journal of Engineering Applied Sciences and Technology*, *4*(5), 371–376.

Bou Nassif, A., Shahin, I., Attili, I., Azzeh, M., & Shaalan, K. (2019). Speech recognition using deep neural networks: A systematic review. *IEEE Access*, *7*, 19143–19165. https://doi.org/10.1109/ACCESS.2019.2896880

Bozüyük, T., Yağcı, C., Gökçe, İ., & Akar, G. (2005). Yapay Zeka Teknolojisinin Endüstrideki Uygulamaları. Marmara Üniversitesi, Teknik Bilimler Meslek Yüksekokulu, Elektrik Programı, İstanbul.

Chen, J. (2023). Model algorithm research based on Python Fast API. *Frontiers in Science and Engineering, 3*(9), 7–10.

Coderspace (2025a). Front-end hakkında bilgi – Nedir, ne demektir? Coderspace. https://coderspace.io/sozluk/front-end/. (Son erişim tarihi: 20 Haziran 2025)

Coderspace (2025b). Back-end hakkında bilgi – Nedir, ne demektir? Coderspace. https://coderspace.io/sozluk/back-end/. (Son erişim tarihi: 20 Haziran 2025)

Çakmakçı, M. F., & Çakmakçı, R. (2023). Uzaktan algılama, yapay zekâ ve geleceğin akıllı tarım teknolojisi trendleri. *Avrupa Bilim ve Teknoloji Dergisi, 52*, 234–246. https://doi.org/10.5281/zenodo.10439935

Çamurcu, H. (2005). Dünya nüfus artışı ve getirdiği sorunlar. *Balıkesir Üniversitesi Sosyal Bilimler Enstitüsü Dergisi, 8*(13), 87–105.

Çetiner, S. (2011). Organik tarım dünyayı besleyebilir mi? In *Tarla Sera Dergisi*. (pp. 64–67)

Çökren, H. A. (2024). *Çevre kontrollü Dikey Tarım İçin Karar Destek Sistemi Geliştirilmesi: Hibrit Afrika Menekşesi Örneği.* (Yayımlanmamış Doktora Tezi, Sakarya Üniversitesi İşletme Enstitüsü)

Demirhan, A., Kılıç, Y. A., & Güler, İ. (2010). Tıpta yapay zekâ uygulamaları. *Yoğun Bakım Dergisi, 9*(1), 31–41.

Dey, B., Ferdous, J., & Ahmed, R. (2024). Machine learning based recommendation of agricultural and horticultural crop farming in India under the regime of NPK, soil pH and three climatic variables. *Heliyon, 10*, e25112. https://doi.org/10.1016/j.heliyon.2024.e25112

DirencNet (2025). 1.8 inch Oled Arduino TFT LCD display module. Direnc.net. https://www.direnc.net/18-inch-128x160-arduino-tft-lcd-oled-ekran-modulu-en (Son erişim tarihi: 15 Haziran 2025)

Doğan, Z., Arslan, S., & Berkman, A. N. (2015). Türkiye'de tarım sektörünün iktisadi gelişimi ve sorunları: Tarihsel bir bakış. *Niğde Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 8*(1), 29–41.

Eker, R., Alkiş, K. C., Uçar, Z., & Aydın, A. (2023). Ormancılıkta makine öğrenmesi kullanımı. *Turkish Journal of Forestry*, *24*(2), 150–177. https://doi.org/10.18182/tjf.1282768

Emekli, N. Y., & Topakçı, M. (2009). Hassas uygulamalı tarım teknolojilerinin sulama alanında kullanımı. *GOÜ Ziraat Fakültesi Dergisi, 26*(2), 9–17.

Ennaji, O., Vergütz, L., & El Allali, A. (2023). Machine learning in nutrient management: A review. *Artificial Intelligence in Agriculture, 9*, 1–11. https://doi.org/10.1016/j.aiia.2023.06.001

Ercan, Ş., Öztep, R., Güler, D., & Saner, G. (2019). Tarım 4.0 ve Türkiye'de uygulanabilirliğinin değerlendirilmesi. *Tarım Ekonomisi Dergisi*, *25*(2), 259–265. https://doi.org/10.24181/tarekoder.650762

Epstein, R., Roberts, G., & Beber, G. (Eds.). (2009). *Parsing the Turing test: Philosophical and methodological issues in the quest for the thinking computer*. Springer Science.

Gilden, R. C., Huffling, K., & Sattler, B. (2010). Pesticides and health risks. *Journal of Obstetric, Gynecologic & Neonatal Nursing*, *39*(1), 103–110. https://doi.org/10.1111/j.1552-6909.2009.01092.x

Gökalp, Ö. M. (2021). *Makine Öğrenmesi*. (Lisans Bitirme Projesi, Gazi Üniversitesi Gazi Bilişim Enstitüsü)

Gupta, S., Jain, N., Chopade, A., & Bhonde, A. (2022). Farmer's assistant: A machine learning based application for agricultural solutions. https://arxiv.org/abs/2204.11340. (Son erişim tarihi: 15 Haziran 2025)

Gültepe, Y. (2019). Makine öğrenmesi algoritmaları ile hava kirliliği tahmini üzerine karşılaştırmalı bir değerlendirme. *Avrupa Bilim ve Teknoloji Dergisi, 16,* 8–15. https://doi.org/10.31590/ejosat.530347

Güzel, M. (2022). *Tokat Bölgesi Buğday Üretiminde Bazı Yabancı Otların Derin Öğrenme Yöntemi İle Tespit Edilmesi.* (Yayımlanmamış Doktora Tezi, Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü)

Güzel, B., & Okatan, E. (2022). Tarım ve yapay zekâ. In *Yapay Zekânın Değiştirdiği Dinamikler*. (pp. 199–224)

Hasan, M., Marjan, M. A., Uddin, M. P., Afjal, M. I., Kardy, S., Ma, S., & Nam, Y. (2023). Ensemble machine learning-based recommendation system for effective prediction of suitable agricultural crop cultivation. *Frontiers in Plant Science, 14*, 1234555. https://doi.org/10.3389/fpls.2023.1234555

Hayaloğlu, P. (2018). İklim değişikliğinin tarım sektörü ve ekonomik büyüme üzerindeki etkileri. *Gümüşhane Üniversitesi Sosyal Bilimler Enstitüsü Elektronik Dergisi, 9*(25), 52–62.

İkas (2025). Yapay zekâ nedir? (En iyi yapay zekâ uygulamaları). https://ikas.com/tr/blog/yapay-zeka-uygulamalari. (Son erişim tarihi: 15 Haziran 2025)

Ikhlaq, U., & Kechadi, T. (2023). Machine learning-based nutrient application's timeline recommendation for smart agriculture: A large-scale data mining approach. In *Proceedings of the International Conference on Intelligent Systems and New Applications (ICISNA'23)*. (pp. 42–47)

İnan, M., & Karcı, A. (2021). Tarımda ağaç ilaçlamanın drone'larla yapılmasında yeni bir yöntemin geliştirilmesi ve uygulanması. *Anatolian Journal of Computer Sciences, 6*(2), 72–89.

Infoldia (2022). Api metodları ve endpoint'lerin önemi. https://www.infoldia.com/blog-detay-138534-API-Metodlari-ve-Endpoint-lerin-Onemi.html. (Son erişim tarihi: 15 Haziran 2025)

Infotech Academy (2025). Front-end ve back-end nedir? https://www.infotechacademy.com.tr/Blog/front-end-ve-back-end-nedir. (Son erişim tarihi: 20 Haziran 2025)

Islam, S., Reza, M. N., Jeong, J.-T., & Lee, K.-H. (2016). Sensing technology for rapid detection of phosphorus in water: A review. *Journal of Biosystems Engineering*, *41*(2), 138–144. https://doi.org/10.5307/JBE.2016.41.2.138

Islam, T., Chisty, T. A., & Chakrabarty, A. (2018). A deep neural network approach for crop selection and yield prediction in Bangladesh. In *2018 21st International Conference of Computer and Information Technology (ICCIT)*. (pp. 1–6)

Kılavuz, E., & Erdem, İ. (2019). Dünyada tarım 4.0 uygulamaları ve Türk tarımının dönüşümü. *Social Sciences (NWSASOS)*, *14*(4), 133–157. https://doi.org/10.12739/NWSA.2019.14.4.3C0189

Kiran, P. S., Abhinaya, G., Sruti, S., & Padhy, N. (2024). A machine learning-enabled system for crop recommendation. *Engineering Proceedings*, *67*(51). https://doi.org/10.3390/engproc2024067051

Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, *60*(6), 84–90. https://doi.org/10.1145/3065386

Küçükönder, H. (2011). *Yapay Sinir Ağları ve Tarımda Bir Uygulama.* (Doktora Tezi, Kahramanmaraş Sütçü İmam Üniversitesi Fen Bilimleri Enstitüsü)

Mega Mühendislik (2022). RS485 seri haberleşme standardı nedir? Mega Mühendislik. https://www.megaplc.com.tr/rs485-seri-haberlesme-standarti/ (Son erişim tarihi: 15 Haziran 2025)

Memmedova, N. (2012). *Süt Sığırlarında Mastitisin Bazı Yapay Zeka Yöntemleri Kullanılarak Erken Dönemde Tespiti.* (Doktora Tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü)

Moonrungsee, N., Pencharee, S., & Jakmunee, J. (2015). Colorimetric analyzer based on mobile phone camera for determination of available phosphorus in soil. *Talanta*, *136*, 204–209. https://doi.org/10.1016/j.talanta.2015.01.024

Musanase, C., Vodacek, A., Hanyurwimfura, D., Uwitonze, A., & Kabandana, I. (2023). Data-driven analysis and machine learning-based crop and fertilizer recommendation system for revolutionizing farming practices. *Agriculture*, *13*(11), 2141. https://doi.org/10.3390/agriculture13112141

Newell, A., & Simon, H. A. (1956). The logic theory machine: A complex information processing system. *IRE Transactions on Information Theory*, *2*(3), 61–79. https://doi.org/10.1109/TIT.1956.1056810

Özcan, S. (2025). Yapay zeka nedir? Örnekleri ve temel işlevleri. Egiteknoloji. https://www.egiteknoloji.com/yapay-zeka-nedir-ornekleri-uygulamalari.html. (Son erişim tarihi: 15 Haziran 2025)

Özkaya, M. (2012). RS485 nedir? Nasıl çalışır? https://mustafaozkaya.com.tr/2012/11/04/rs485-nedir-nasil-calisir/. (Son erişim tarihi: 15 Haziran 2025)

Öztürk, K., & Şahin, M. E. (2018). Yapay sinir ağları ve yapay zekâ'ya genel bir bakış. *Takvim-i Vekayi*, *6*(2), 25–36.

Parameswari, P., Rajathi, N., & Harshanaa, K. J. (2021). Machine learning approaches for crop recommendation. In *2021 International Conference on Advancements in Electrical, Electronics, Communication, Computing and Automation (ICAECA)*. (pp. 1–5)

Patel, K., & Patel, H. B. (2023). Multi-criteria agriculture recommendation system using machine learning for crop and fertilizers prediction. *Current Agriculture Research Journal*, *11*(1), 137–149. https://doi.org/10.12944/CARJ.11.1.12

Pati, S., & Zaki, Y. (2025). Evaluating the efficacy of Next.js: A comparative analysis with React.js on performance, SEO, and global network equity. In *Companion Proceedings of the ACM on Web Conference 2025*. (pp. 1239–1243)

Pirim, H. (2006). Yapay zeka. *Journal of Yaşar University*, *1*(1), 81–93.

PSA Teknoloji (2025). Endpoint nedir? Ne işe yarar? PSA Teknoloji. https://psateknoloji.com/endpoint-nedir-ne-ise-yarar/ (Son erişim tarihi: 20 Haziran 2025)

Rehber, E., & Turhan, S. (2002). Prospects and challenges for developing countries in trade and production of organic food and fibers: The case of Turkey. *British Food Journal*, *104*(3/4/5), 371–390.

Rasulov, H. R. (2024). FASTAPI: A modern web framework for Python. *Asia International Journal of Multidisciplinary Research*, *8*(1), 727–730.

Ryan, M., Isakhanyan, G., & Tekinerdogan, B. (2023). An interdisciplinary approach to artificial intelligence in agriculture. *NJAS: Impact in Agricultural and Life Sciences*, *95*(1). https://doi.org/10.1080/27685241.2023.2168568

Samuel, A. L. (1959). Some studies in machine learning using the game of checkers. *IBM Journal of Research and Development*, *3*(3), 210–229. https://doi.org/10.1147/rd.33.0210

Shenzhen Yingke Interactive Technology Co., Ltd. (2025). CWT soil sensor (NPK type) manual (Version 1.0). https://www.comwintop.com. (Son erişim tarihi: 20 Haziran 2025)

Silver, D., Huang, A., Maddison, C. J., Guez, A., Sifre, L., van den Driessche, G., Schrittwieser, J., Antonoglou, I., Panneershelvam, V., Lanctot, M., Dieleman, S., Grewe, D., Nham, J., Kalchbrenner, N., Sutskever, I., Lillicrap, T., Leach, M., Kavukcuoglu, K., Graepel, T., & Hassabis, D. (2016). Mastering the game

of Go with deep neural networks and tree search. *Nature, 529*(7587), 484–489. https://doi.org/10.1038/nature16961

Singh, G., & Sharma, S. (2025). Enhancing precision agriculture through cloud-based transformative crop recommendation model. *Scientific Reports, 15*(9138), 1–19. https://doi.org/10.1038/s41598-025-93417-3

Sönmez, İ., Kaplan, M., & Sönmez, S. (2008). Kimyasal gübrelerin çevre kirliliği üzerine etkileri ve çözüm önerileri. *Batı Akdeniz Tarımsal Araştırma Enstitüsü Derim Dergisi*, *25*(2), 24–34.

Şahin, G. (2016). Türkiye'de gübre kullanım durumu ve gübreleme konusunda yaşanan problemler. *Tarım Ekonomisi Dergisi*, *22*(1), 19–31.

Tanaka, T. S. T., Heuvelink, G. B. M., Mieno, T., & Bullock, D. S. (2024). Can machine learning models provide accurate fertilizer recommendations? *Precision Agriculture*, *25*, 1839–1856. https://doi.org/10.1007/s11119-024-10136-x

Temizel, K. E., & Koç, Y. (2015). Coğrafi bilgi sisteminin hassas tarımda uygulanmasının yararları: Gübreleme örneği. *Anadolu Tarım Bilimleri Dergisi, 30*(2), 130–135. https://doi.org/10.7161/anajas.2015.30.2.130-135

Terzi, İ., Özguven, M. M., Altaş, Z., & Uygun, T. (2019). Tarımda yapay zekâ kullanımı. International Erciyes Agriculture, Animal & Food Sciences Conference. https://www.researchgate.net/publication/338162801. (Son erişim tarihi: 15 Haziran 2025)

Tiryaki, O., Canhilal, R., & Horuz, S. (2010). Tarım ilaçları kullanımı ve riskleri. *Erciyes Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, *26*(2), 154–169.

Tıraş, H. H. (2012). Sürdürülebilir kalkınma ve çevre: Teorik bir inceleme. *Kahramanmaraş Sütçü İmam Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, *2*(2), 57–73.

Turan, A. (2022). *Organik Ve Geleneksel Tarım Yapılan Alanlardaki Bazı Toprak Kalite Parametrelerinin Spektroradyometrik Yöntemlerle Karakterize Edilmesi.* (Yayımlanmamış Yüksek Lisans Tezi, Harran Üniversitesi Fen Bilimleri Enstitüsü)

Türkoğlu, A. (1958). Dünya nüfusu ve beslenme problemi. *İstanbul Üniversitesi İktisat Fakültesi Mecmuası*, *20*(1–4), 34–60.

Turgut, O., Kök, I., & Özdemir, S. (2024). AgroXAI: Explainable AI-driven crop recommendation system for Agriculture 4.0. In *2024 IEEE International Conference on Big Data (Big Data).* (pp. 7208–7217)

UltaHost (2024). API uç noktası nedir? Neden bu kadar önemliler? https://ultahost.com/blog/tr/api-endpoint-nedir-neden-bu-kadar-onemliler/. (Son erişim tarihi: 20 Haziran 2025)

Ünal, İ., Sözer, S., Kabaş, Ö., Çetin, S., & Topakcı, M. (2016). Üç farklı yapay sinir ağı yöntemi kullanılarak toprak penetrasyon direnci tahmini. *Tarım Makinaları Bilimi Dergisi, 12*(2), 95–102.

Üren, F. (2023). Arduino nedir? Ne işe yarar? Robotistan Maker. https://maker.robotistan.com/arduino-nedir-ne-ise-yarar/. (Son erişim tarihi: 15 Haziran 2025)

Uzun, Y., Bilban, M., & Arıkan, H. (2018). Tarım ve kırsal kalkınmada yapay zekâ kullanımı. VI. KOP Bölgesel Kalkınma Sempozyumu (KOPBKS), (Türkiye). https://www.researchgate.net/publication/328570324. (Son erişim tarihi: 15 Haziran 2025)

Uzun, Y., Hatipoğlu, M., Bütüner, R., & Calp, M. H. (2021, Kasım). Yapay zekâ insan zekâsını geçebilecek mi? In *Uluslararası Mühendislik, Doğa ve Sosyal Bilimler Sempozyumu (ISENS-21): Enerji ve Toplum.* (pp. 225–228)

Yağmur, B. (2009). Farklı seviyelerde uygulanan potasyumun anasonun verim ve yaprak besin maddesi içeriğine etkisi. *Ege Üniversitesi Ziraat Fakültesi Dergisi, 46*(1), 17–24.

Yaraş, K., & Daşgan, H. Y. (2012). Sera koşullarında toprağa uygulanan kükürt ve organik maddenin toprak pH'sı, domatesin bitki büyümesi, verimi ve meyve kalitesi üzerine etkisi. *Tarım Bilimleri Araştırma Dergisi, 5*(1), 175–180.

Yılmaz, H., Demircan, V., & Gül, M. (2009). Üreticilerin kimyasal gübre kullanımında bilgi kaynaklarının belirlenmesi ve tarımsal yayım açısından değerlendirilmesi. *Süleyman Demirel Üniversitesi Ziraat Fakültesi Dergisi, 4*(1), 31–44.

Yılmaz, Ş. (2025). Arduino temel bilgiler. https://www.arduinoturkiye.com/ (Son erişim tarihi: 15 Haziran 2025)

Zebec, V., Rastija, D., Lončarić, Z., Bensa, A., Popović, B., & Ivezić, V. (2017). Comparison of chemical extraction methods for determination of soil potassium in different soil types. *Eurasian Soil Science, 50*(12), 1420–1431. https://doi.org/10.1134/S1064229317130051