



T.C.  
NECMETTİN ERBAKAN  
ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ



**GELECEĞİN TARIMI: İoT VE YAPAY ZEKA  
İLE SÜRDÜRÜLEBİLİR SERA YÖNETİMİ**

**Kerim BEŞİR**

**YÜKSEK LİSANS TEZİ**

**Mekatronik Mühendisliği Anabilim Dalı**

**Aralık-2025  
KONYA  
Her Hakkı Saklıdır**

## TEZ KABUL VE ONAYI

Kerim BEŞİR tarafından hazırlanan “Geleceğin Tarımı: IoT ve Yapay Zeka ile Sürdürülebilir Sera Yönetimi” adlı tez çalışması 08/12/2025 tarihinde aşağıdaki jüri tarafından oy birliği ile Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü Mekatronik Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS olarak kabul edilmiştir.

### Jüri Üyeleri

### İmza

#### Başkan

Prof. Dr. Özlem COŞKUN

.....

#### Danışman

Dr. Öğr. Üyesi Halime ERGÜN

.....

#### Üye

Dr. Öğr. Üyesi Yusuf UZUN

.....

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

Prof. Dr. Havvanur UÇBEYİAY  
FBE Müdürü

## TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

## DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

İmza

Kerim BEŞİR

Tarih: 16.12.2025

## ÖZET

### YÜKSEK LİSANS TEZİ

## GELECEĞİN TARIMI: İoT VE YAPAY ZEKA İLE SÜRDÜRÜLEBİLİR SERA YÖNETİMİ

Kerim BEŞİR

NECMETTİN ERBAKAN ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ  
MEKATRONİK MÜHENDİSLİĞİ ANABİLİM DALI

Danışman: Dr. Öğr. Üyesi Halime ERGÜN

2025, 52 Sayfa

Jüri

Dr. Öğr. Üyesi Halime ERGÜN  
Prof. Dr. Özlem COŞKUN  
Dr. Öğr. Üyesi Yusuf UZUN

Bu tezde, çilek yetiştiriciliğinde sürdürülebilir sera yönetimini desteklemek amacıyla, sensör tabanlı bir Nesnelerin İnterneti (IoT) altyapısı ile makine öğrenmesine dayalı haftalık verim tahminini bir araya getiren akıllı bir sera prototipi geliştirilmiş ve gerçek koşullarda test edilmiştir. ESP32 tabanlı bir kontrol birimi aracılığıyla; sıcaklık, bağıl nem, hava kalitesi, toprak nemi ve ışık şiddeti sensörlerinden 15 dakikalık aralıklarla veri toplanmıştır. Elde edilen çok değişkenli zaman serileri hem bir IoT bulut platformuna hem de yerel belleğe kaydedilmiştir. Bu sayede sera içi koşullardaki ani değişimler çevrimiçi izlenebilmiş; fan, ısıtıcı ped ve sulama pompası önceden belirlenen eşik değerlere göre otomatik olarak çalıştırılarak ortam parametreleri hedef aralıklarda tutulmuştur.

Veri işleme sürecinde ölçümler saatlik ve günlük düzeyde özetlenmiş; günlük ışık yükünü temsil eden yaklaşık Günlük Işık İntegrali (DLI) ve sıcaklığa dayalı Büyüme Derecesi Günleri (GDD) göstergeleri türetilmiştir. Düzensiz aralıklarla kaydedilen hasat miktarları, (i) kütleyi koruyan doğrusal kümülatif enterpolasyon ve (ii) DLI temelli ağırlıklandırılmış dağıtım yaklaşımlarıyla önce günlük, ardından haftalık verim serilerine dönüştürülerek çevresel verilerle aynı zaman ekseninde hizalanmıştır. Verim tahmininde çıktı değişkeni haftalık toplam verim olarak tanımlanmış; girdi özellikleri ise her haftadan önceki dönemi kapsayan yedi günlük kaydırmalı pencerelerden elde edilen DLI ve GDD birikimleri ile sensör ölçümlerinin ortalamalarından oluşturulmuştur. Böylece verimin tek bir güne ait anlık koşullardan ziyade, bir hafta boyunca biriken mikroiklim etkilerinin bileşik sonucu olduğu varsayımını yansıtan bir özellik uzayı elde edilmiştir.

Modelleme aşamasında doğrusal regresyon, Random Forest ve Gradient Boosting algoritmaları ile tahmin modelleri kurulmuş; performans k-katlı çapraz doğrulama ile değerlendirilmiştir. En yüksek başarı, Gradient Boosting modelinde yaklaşık  $R^2 = 0,94$  düzeyinde elde edilmiş ve hata metrikleri haftalık verim ile çevresel koşullar arasındaki ilişkinin güçlü biçimde yakalandığını göstermiştir. Çalışmanın temel katkıları; (i) gerçek sensör verileri ile manuel hasat kayıtlarını entegre eden, gerçek zamanlı veri toplama, çevrimiçi izleme ve otomasyon işlevlerini bir araya getiren düşük maliyetli bir akıllı sera altyapısının geliştirilmesi, (ii) düzensiz zamanlı hasat kayıtlarını kütle korunumlu ve ışık temelli ağırlıklandırma yaklaşımlarıyla günlük/haftalık serilere dönüştüren esnek bir analiz çerçevesinin önerilmesi ve (iii) çilek verimini haftalık ölçekte anlamlı doğrulukla tahmin edebilen makine öğrenmesi tabanlı bir karar destek modelinin sunulmasıdır.

**Anahtar Kelimeler:** Akıllı sera, çilek, günlük ışık integrali, kütleyi koruyan enterpolasyon, makine öğrenmesi, nesnelerin interneti, verim tahmini.

## ABSTRACT

### MS THESIS

# FUTURE FARMING: SUSTAINABLE GREENHOUSE MANAGEMENT WITH IoT AND ARTIFICIAL INTELLIGENCE

**Kerim BEŞİR**

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

**Advisor: Asst. Prof. Dr Halime ERGUN**

**2025, 52 Pages**

**Jury**

**Asst. Prof. Dr Halime ERGUN**

**Prof. Dr. Özlem COŞKUN**

**Asst. Prof. Dr Yusuf UZUN**

This thesis develops and evaluates a smart greenhouse prototype under real-world conditions by integrating a sensor-based Internet of Things (IoT) infrastructure with machine learning-based weekly yield prediction to support sustainable strawberry greenhouse management. An ESP32-based control unit collected temperature, relative humidity, air quality, soil moisture, and light intensity data at 15-minute intervals. The resulting multivariate time series were stored both on an IoT cloud platform and in local memory. This architecture enabled online monitoring of abrupt environmental changes, while a fan, heating pad, and irrigation pump were automatically actuated according to predefined threshold values to maintain greenhouse parameters within target ranges.

During data processing, measurements were aggregated at hourly and daily resolutions, and two derived indicators were computed: an approximate Daily Light Integral (DLI) representing daily light load and Growing Degree Days (GDD) reflecting temperature-driven development. Harvest quantities recorded at irregular intervals were transformed into daily and subsequently weekly yield series using (i) mass-preserving cumulative linear interpolation and (ii) DLI-based weighted redistribution, thereby aligning yield and environmental variables on a common time axis. For yield prediction, weekly total yield was defined as the output variable, while input features were constructed from seven-day rolling windows preceding each week, combining cumulative DLI and GDD values with mean sensor measurements. This feature design reflects the assumption that yield is driven by the cumulative effects of microclimatic conditions over a week rather than by single-day snapshots.

Prediction models were developed using linear regression, Random Forest, and Gradient Boosting and were evaluated via k-fold cross-validation. The Gradient Boosting model achieved the best performance with an  $R^2$  of approximately 0.94, and the error metrics indicated that the relationship between weekly yield and environmental conditions was captured effectively. The main contributions of this study are: (i) the development of a low-cost smart greenhouse platform that integrates real-time sensing, online monitoring, and automated control while linking sensor streams with manual harvest records; (ii) the proposal of a flexible analytical framework for converting irregular harvest records into daily and weekly yield series through mass-preserving and light-weighted approaches; and (iii) the development of a machine learning-based decision-support model capable of predicting weekly strawberry yield with high accuracy based on microclimate indicators.

**Keywords:** Smart greenhouse, strawberry, daily light integral, mass-conserving interpolation, machine learning, internet of things, yield prediction.

## ÖNSÖZ

Küresel iklim değışikliđi ve artan gıda talebi karşısında tarımsal üretimin sürdürülebilirliđi, modern mühendislik çözümlerinin bu alana entegrasyonunu zorunlu kılmıştır. "Geleceđin Tarımı: IoT ve Yapay Zeka ile Sürdürülebilir Sera Yönetimi" başlıklı bu tez çalışması, Nesnelerin İnterneti (IoT) ve makine öğrenmesi tekniklerini bir araya getirerek çilek yetiştiriciliđinde veri odaklı ve verimli bir yönetim modeli sunmayı amaçlamaktadır.

Bu çalışmanın her aşamasında değerli bilgi ve tecrübeleriyle yolumu aydınlatan, akademik rehberliđini ve desteđini hiçbir zaman esirgemeyen danışman hocam Dr. Öğr. Üyesi Halime ERGÜN'e en içten teşekkürlerimi sunarım. Ayrıca jüri üyelerimin çalışmaya sağladıkları değerli katkılar ve değerlendirmeleri için teşekkür ederim.

Çalışmam boyunca prototipin oluşturulmasında ve veri toplama süreçlerinde yardımlarını gördüğüm tüm çalışma arkadaşlarıma ve eğitim hayatım boyunca beni her zaman destekleyen, sabır ve sevgiyle yanımda olan kıymetli aileme teşekkür borçluyum. Bu tezin, akıllı tarım ve tarımsal otomasyon alanında çalışma yapacak araştırmacılara faydalı bir kaynak olmasını temenni ederim.

Kerim BEŞİR  
KONYA-2025

# İÇİNDEKİLER

ÖZET .....	iv
ABSTRACT.....	v
ÖNSÖZ .....	vi
ŞEKİLLER LİSTESİ .....	ix
TABLolar LİSTESİ .....	x
SİMGELER VE KISALTMALAR .....	xi
<b>1. GİRİŞ .....</b>	<b>1</b>
<b>2. KAYNAK ARAŞTIRMASI .....</b>	<b>4</b>
<b>3. MATERYAL VE YÖNTEM.....</b>	<b>6</b>
3.1. Donanım Bileşenleri .....	7
3.1.1. Kontrol Kartı.....	7
3.1.2. Kart Modülü.....	8
3.1.3. Sıcaklık ve Nem Sensörü .....	9
3.1.4. Işık Şiddeti Sensörü .....	10
3.1.5. Hava Kalitesi Sensörü.....	10
3.1.6. Toprak Nem Sensörü .....	11
3.1.7. Havalandırma Fanı.....	12
3.1.8. Röle Modülü .....	13
3.1.9. Su Pompası Motoru.....	13
3.2. Sera Prototipi .....	14
3.2.1. Fiziksel Tasarım.....	14
3.2.2. Bulut Ortamı ve Veri Akışı.....	17
3.2.3. Hatalı ve Eksik Verilerin Kontrolü .....	17
3.3. Veri Setinin Oluşturulması .....	18
3.3.1. Hasat Verilerinin Günlük Verime Dönüştürülmesi .....	18
3.3.2. Günlük Işık İndeksi (DLI) .....	21
3.3.3. Büyüme Derece Günleri (GDD) .....	22
3.3.4. Kaydırmalı Zaman Pencereleri .....	23
3.4. Verim Tahmin Modelleri.....	23
3.4.1. Lineer Regresyon .....	24
3.4.2. Random Forest .....	24
3.4.3. Gradient Boosting .....	25
3.4.4. Çapraz Doğrulama .....	25
3.4.5. Değerlendirme Ölçütleri .....	26
<b>4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....</b>	<b>27</b>
4.1. Verilerin Analizi .....	28
4.2. Verim Tahmini .....	33

<b>5. SONUÇLAR VE ÖNERİLER .....</b>	<b>36</b>
<b>6. KAYNAKLAR .....</b>	<b>37</b>



## ŞEKİLLER LİSTESİ

Şekil 3.1. ESP32 tabanlı akıllı tarım otomasyon sisteminin donanım mimarisi. ....	6
Şekil 3.2. ESP32 Mikrodenetleyici.....	8
Şekil 3.3. ESP32 ile MicroSD modülünün devre bağlantısı.....	9
Şekil 3.4. DHT22 sıcaklık-nem sensörü.....	9
Şekil 3.5. BH1750 ışık sensörü .....	10
Şekil 3.6. MQ-135 sensör modülü.....	11
Şekil 3.7. Toprak nem sensörü: nem ölçer problar ve gerilim karşılaştırma kartı .....	12
Şekil 3.8. Havalandırma Fanı .....	12
Şekil 3.9. Röle modülü .....	13
Şekil 3.10. Su pompası motoru.....	14
Şekil 3.11. Prototip seranın genel görünümleri .....	15
Şekil 3.12. Sera devre elemanlarının prototip yerleşimi. ....	16
Şekil 4.1. Oluşturulan akıllı sera prototipi.....	27
Şekil 4.2. Adafruit IO platformu üzerinde sensör değerlerinin anlık gösterimi .....	28
Şekil 4.3. Çoklu sensör verilerinin zaman serisi gösterimi (ilk 500 kayıt). ....	29
Şekil 4.4. Seradan elde edilen çilek hasatlarına ait görüntüler .....	31
Şekil 4.5. Hasat miktarının zamana göre dağılımı.....	32

## TABLULAR LİSTESİ

<b>Tablo 4.1.</b> Sensör verilerinin istatistik özet değerleri .....	30
<b>Tablo 4.2.</b> Çalışma süresince elde edilen çilek hasatlarına ait özet istatistikler. ....	32
<b>Tablo 4.3.</b> Lineer dağıtılan verim için tahmin modellerinin performansları.....	33
<b>Tablo 4.4.</b> DLI ile ağırlıklandırılmış verim için tahmin modellerinin performansları...	34



## SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

### SİMGELER

°C	Sıcaklık birimi
lux	Aydınlatma şiddeti (ışık)
ppm	Gaz yoğunluğu birimi

### KISALTMALAR

ADC	Analog-to-Digital Converter (Analogdan Sayısal Dönüştürücü)
CO <sub>2</sub>	Karbondiyoksit
I <sup>2</sup> C	Inter-Integrated Circuit (Cihazlar Arası Seri İletişim Protokolü)
IP	Internet Protocol (İnternet Protokolü)
IoT	Internet of Things (Nesnelerin İnterneti)
MAE	Mean Absolute Error (Ortalama Mutlak Hata)
NH <sub>3</sub>	Amonyak
R <sup>2</sup>	Determinasyon Katsayısı (Modelin açıklayıcılık oranı)
RMSE	Root Mean Square Error (Kök Ortalama Kare Hatası)
VOC	Volatile Organic Compounds (Uçucu Organik Bileşikler)
DLI	Daily Light Integral (Günlük Işık İndeksi)
GDD	Growing Degree Days (Büyüme Derece Günleri)
VPD	Vapor Pressure Deficit (Buhar Basıncı Açığı)
CV	Cross-Validation (Çapraz Doğrulama)

## 1. GİRİŞ

Küresel ölçekte artan gıda talebi, iklim değişikliği ve doğal kaynakların kısıtlılığı, tarımsal üretimde sürdürülebilir ve veri odaklı yaklaşımların önemini her geçen gün artırmaktadır. Bu bağlamda, kontrollü ortam tarımı ve sera yetiştiriciliği, özellikle yüksek katma değerli ve iklim koşullarına hassas ürünler için kritik bir rol üstlenmektedir. Ancak geleneksel sera sistemleri, çoğu zaman gerçek zamanlı izleme ve veriye dayalı karar mekanizmalarından yoksun olduğu için, yetiştirme koşullarının sistematik biçimde optimize edilememektedir. Buna bağlı olarak da verim kayıpları ve su, enerji gibi kaynakların verimsiz kullanımıyla sonuçlanmaktadır (Sun vd., 2022; Rodríguez vd., 2021).

Sensör teknolojilerindeki, kablosuz iletişim altyapılarındaki ve Nesnelerin İnterneti (IoT) platformlarındaki gelişmeler, sera içi mikroiklimin düşük maliyetle ve yüksek zaman çözünürlüğüyle izlenmesini mümkün hale getirmiştir. Aynı zamanda bu verilerin bulut tabanlı sistemlerde saklanması ve işlenmesi için yeni fırsatlar doğurmaktadır (Rodríguez vd., 2021). IoT tabanlı akıllı sera uygulamaları, sıcaklık, bağıl nem, ışık şiddeti, toprak nemi ve hava kalitesi gibi çevresel büyüklüklerin sürekli ölçülmesine ve bu ölçümlere dayalı otomatik kontrol stratejilerinin geliştirilmesine imkan tanımaktadır. Buna paralel olarak, yapay zeka ve makine öğrenmesi algoritmaları, sensörlerden elde edilen verileri kullanarak verim tahmini, erken uyarı ve koşul optimizasyonu gibi üst seviye işlevlerin gerçekleştirilmesini mümkün kılmaktadır.

IoT sistemleri; toprak nemi, sıcaklık, bağıl nem ve su seviyesi gibi kritik tarımsal parametrelerin gerçek zamanlı toplanması ve izlenmesini kolaylaştırarak, hassas tarım ve akıllı sulama uygulamalarına zemin hazırlar; böylece kaynak kullanımı optimize edilir ve atıklar azaltılır (Pinto vd., 2024; Adediran vd., 2024; Bhardwaj vd., 2024). Adafruit IO gibi bulut servisleri, NodeMCU ve ESP32 mikrodenetleyicileriyle bütünleştiğinde, çiftçiler için uzaktan izleme ve kontrol imkanı sunan uygun maliyetli ve kullanıcı dostu bir platform oluşur. Ayrıca bu sistemler, çevresel etkiyi en aza indirmek amacıyla güneş enerjisi gibi yenilenebilir kaynaklarla beslenebilmektedir (Vijayaraja vd., 2022).

IoT'nin akıllı çiftçilikteki rolü; bitki üretiminin yanı sıra hayvancılık izleme ve tedarik zinciri yönetimine uzanarak tarımsal sürdürülebilirliğe bütüncül bir yaklaşım sunar (Adediran vd., 2024). Yapay zeka ve IoT entegrasyonu, kendi kendini idame ettiren tarım sistemlerinin geliştirilmesini destekler ve karar verme yeteneklerini ileri düzeyde güçlendirir (Sales, 2025). IoT teknolojileri, artan küresel nüfus karşısında gıda güvenliği

ve çevre koruma zorluklarını ele alarak geleneksel tarımı daha verimli, sürdürülebilir ve esnek bir modele dönüştürmede kritiktir (Singh vd., 2025; Bhardwaj vd., 2024). Sera ortamlarında IoT tabanlı sistemler, gerçek zamanlı izleme ve kontrol yoluyla sıcaklık, nem ve toprak nemi gibi koşulları optimize edecek şekilde tasarlanır; sulama, havalandırma ve aydınlatma süreçlerini çeşitli sensörler ve mikrodenetleyicilerle otomatikleştirerek ürün verimi ve kalitesini artırır (Tatlas vd., 2015; Sahu ve Mazumdar, 2012; Dharani vd., 2022; Zhang, 2018). Adafruit IO gibi platformların dahil olduğu IoT ekosistemi hem küçük ölçekli kentsel tarım hem de büyük ölçekli işletmeler için hassas çevre yönetimi sağlar ve sonuçta daha verimli ve sürdürülebilir uygulamalara katkıda bulunur (Noureddine vd., 2024; Singh & Hota, 2022).

Çilek yetiştiriciliği; sıcaklık, bağıl nem, toprak nemi, hava kalitesi ve ışık yoğunluğu gibi çevresel faktörlerdeki dalgalanmalara karşı oldukça duyarlıdır. Bu parametrelerin hatalı yönetimi hem toplam verimde hem de meyve kalitesinde belirgin kayıplara yol açabilmektedir. Özellikle çilek gibi narin ürünlerde verim tahmini, üretim planlaması, iş gücü yönetimi ve pazarlama stratejilerinin doğru kurgulanması açısından önemlidir. Bu nedenle, sensör verileriyle desteklenen ve çevresel koşullar ile verim arasındaki ilişkiyi nicel olarak ortaya koyabilen veri odaklı modeller, çilek üretiminde önemli bir karar destek aracı olarak değerlendirilebilir (Sun vd., 2022; Rodríguez vd., 2021).

Literatürde, akıllı tarım sistemleri tasarlamaya ve sera iklim kontrolünü iyileştirmeye odaklanan çok sayıda çalışma bulunmaktadır. Bununla birlikte, çilek gibi çevresel koşullara son derece hassas, kısa raf ömrüne ve yüksek ekonomik değere sahip ürünler için, verim tahminini de içeren, özelleştirilebilir, uygun maliyetli ve kolayca ölçeklenebilir akıllı sera çözümlerine geliştirilmesine ihtiyaç bulunmaktadır.

### *Araştırmanın amacı*

Bu çalışma, çilek bitkisinin yetiştirildiği küçük ölçekli bir serada, sıcaklık, bağıl nem, hava kalitesi, toprak nemi, ışık seviyesi ve vb. sensörleriyle oluşturulmuş bir IoT altyapısı kurmakta; bu altyapı üzerinden toplanan çevresel veriler ile çilek verimi arasındaki ilişkinin istatistiksel ve hesaplamalı yöntemlerle modellenmesini amaçlamaktadır. Çalışmanın temel hedefi, uygun maliyetli sensörler ve ESP32 tabanlı bir gömülü sistem kullanarak çevresel parametrelerin gerçek zamanlı olarak izlenmesini

sağlamak, bu verilerden türetilen özellikler aracılığıyla haftalık verimi tahmin eden makine öğrenmesi modelleri geliştirmek ve böylece sürdürülebilir, verimliliği artırıcı bir sera yönetim sistemine yönelik temel bir çerçeve önermektir.

### *Araştırmanın önemi*

Tarımda verim tahmininin doğruluğu, üretim planlaması, hasat lojistiği ve pazar dengesi üzerinde doğrudan belirleyicidir. Özellikle iklimsel dalgalanmalara duyarlı ve raf ömrü kısa olan çilek gibi ürünlerde, yanlış zamanlama ve hatalı verim öngörülleri hem ekonomik kayıpları hem de gıda israfını artırmaktadır. Geleneksel sera uygulamalarında anlık izleme ve veri odaklı kontrol mekanizmalarının sınırlı olması, çevresel değişkenliklerin verime olumsuz yansımalarına ve su, enerji gibi girdilerin verimsiz kullanımına yol açmaktadır.

Nesnelerin interneti tabanlı sensör ağları ve bulut bilişim altyapıları sayesinde, sera mikroikliminin yüksek zaman çözünürlüğünde izlenmesi ve bu verilerden hareketle öngörüye dayalı müdahale stratejileri geliştirilmesi mümkün kılınmıştır.

Literatür, akıllı sera çözümlerinin iklim kontrolünde iyileşme ve üretkenlikte artış sağladığını; özellikle toprak nemi ve ışık yönetiminin otomasyonu ile performansın daha da yükseltilebildiğini göstermektedir (Sun vd., 2022; Rodríguez vd., 2021; Zhang vd., 2023; Kim vd., 2022). Bu çalışma, düşük maliyetli donanım ve yerel koşullara uyarlanabilir ve ölçeklenebilir bir referans prototip sunarak, söz konusu kazanımları çilek yetiştiriciliği özelinde somutlaştırmakta ve gelecekte geliştirilebilecek daha kapsamlı akıllı sera sistemleri için bir başlangıç noktası oluşturmaktadır.

## 2. KAYNAK ARAŞTIRMASI

Nesnelerin interneti ve yapay zeka entegrasyonuna dayalı sürdürülebilir sera yönetimi, iklim değişikliği, kaynak kıtlığı ve artan verim ihtiyacına yönelik önemli bir çözüm yaklaşımı sunmaktadır. IoT tabanlı izleme ve kontrol sistemlerinin yapay zeka ile birlikte kullanılması, sera ortamının gerçek zamanlı yönetilmesini sağlayarak su ve enerji kullanımını optimize ederken bitki için uygun mikroiklim koşullarının sürekliliğini sağlamaktadır. IoT temelli bir sulama sistemiyle, geleneksel yöntemlere kıyasla dekara yaklaşık 25 ton su tasarrufu sağlanabildiği ve su israfı ile işçilik maliyetlerinde anlamlı azalmalar elde edilmiştir (Eriş vd., 2022).

Geleneksel tarımda çevresel parametrelerin manuel izlenmesi ve deneyime dayalı karar alma süreçleri, özellikle kontrollü ortam tarımında verim kayıplarına ve kaynak israfına yol açmaktadır. Bu sorunları azaltmak amacıyla geliştirilen akıllı tarım teknolojileri ise IoT tabanlı sensör ağları, kablosuz iletişim ve yapay zeka destekli analiz yöntemleriyle tarımsal süreçlerin otomatikleştirilmesini, izlenmesini ve optimize edilmesini mümkün kılmaktadır (Miller vd., 2025). IoT teknolojileri, tarımda sıcaklık, nem, ışık, toprak nemi ve CO<sub>2</sub> gibi çevresel parametrelerin sensörlerle gerçek zamanlı izlenmesini ve verilerin kablosuz ağlar aracılığıyla bulut tabanlı sistemlere aktarılmasını sağlamaktadır. Bu sayede verimlilik artmakta, su ve enerji kullanımı azalmakta ve daha bilinçli kararlar alınabilmektedir (Benyezza vd., 2023). ESP32 gibi düşük maliyetli donanımlar ise bu sistemleri küçük ölçekli üreticiler için de ulaşılabilir kılmaktadır (Haziq vd., 2022).

Güncel araştırmalar, akıllı seralarda sensör tabanlı geri bildirim döngülerinin kullanılmasının ürün veriminde ve kalite parametrelerinde belirgin iyileşmeler sağladığını ortaya koymaktadır. Özellikle sıcaklık, ışık ve toprak nemi gibi temel değişkenlerin otomatik kontrol süreçlerine dahil edilmesi, bitki büyümesi için gerekli optimum koşulların korunmasına yardımcı olmaktadır (Zhang vd., 2023; Raj ve Prahadeeswaran, 2025). Ayrıca bulut tabanlı IoT platformlarının, sensör verilerinin görselleştirilmesi, geçmiş kayıtların tutulması ve sistemin uzaktan kontrol edilmesine imkan tanınması, sera yönetiminde esnekliği ve izlenebilirliği artırmaktadır (Mansoor vd., 2025).

Son yıllarda tarım sektöründe yapay zeka ve makine öğrenmesi uygulamalarının yaygınlaşması, sensör verilerinin yalnızca izleme amacıyla değil, ileri düzey analiz ve öngörü için de kullanılmasını mümkün kılmıştır. Çok değişkenli zaman serilerinden elde

edilen verilerle bitki gelişim dinamiklerini modellenmesi ve verim tahmininde bulunulması, tarımsal planlamanın önemli bir bileşeni haline gelmiştir. Makine öğrenmesi algoritmalarının tarımsal veri analizinde öne çıkmasının başlıca nedenleri; büyük veri setlerini işleyebilmeleri, değişkenler arasındaki doğrusal olmayan ilişkileri yakalayabilmeleri ve sensör kaynaklı gürültüyü belirli ölçüde filtreleyebilmeleridir (Del-Coco vd., 2024). Literatürde, Random Forest, Gradient Boosting, yapay sinir ağları ve Destek Vektör Regresyonu gibi algoritmaların sera verim tahmininde başarılı performans sergilediği bildirilmiştir (Miller vd., 2025).

Yapay zeka, sera yönetimde proaktif karar vermeyi mümkün kılmaktadır. Isı ve ışık birikiminden türetilen parametrelerin makine öğrenmesi modelleriyle birlikte kullanılması, bitki büyümesi ve verimin daha isabetli tahmin edilmesine olanak tanımaktadır. Bu tür birikimli göstergelerin model performansını artırdığı belirtilmiştir (Raj & Prahadeeswaran, 2025; Mansoor vd., 2025). Ayrıca IoT–YZ tabanlı erken uyarı sistemleri, zararlı etkileri erken dönemde tespit ederek olası verim kayıplarını azaltmaya yardımcı olmaktadır.


Çilek verimiyle ilgili çalışmalarda, üretim eğilimlerini incelemek ve yapay zeka tabanlı tahmin modellerini eğitmek için örnek veri setleri sıkça kullanılmaktadır. Bu veri kümeleri, gerçek üretim koşulları hakkında da bilgi sunmaktadır. Manzanita Berry Çiftlikleri'nden elde edilen veri seti, 2 Şubat–22 Haziran 2018 tarihleri arasında her 3–4 günde bir yapılan ölçümlerden oluşmakta ve toplam 36 gözlem içermektedir (Maskey vd., 2019). Haftalık analiz gerektiren çalışmalarda ise enterpolasyon yöntemleriyle düzensiz gözlemlerden yedi günlük toplam verim değerleri elde edilmiştir. Bu kapsamda, Snyder et al. (1996) ve Marino et al. (2019) tarafından önerilen enterpolasyon yaklaşımı temel alınmış ve haftalık bazda düzenlenmiş veriler üzerinden analizler gerçekleştirilmiştir.

Çevresel verilerin sürekli toplanması, bu verilere dayalı otomasyon ve verim tahmini modelleriyle birleştirildiğinde hem kaynak kullanımı iyileşmekte hem de sürdürülebilir ve verimli üretim mümkün olmaktadır. Bu nedenle, IoT tabanlı sensör altyapıları ile yapay zeka destekli verim tahmini modellerinin birlikte kullanımı, geleceğin tarım uygulamalarının temel bileşenlerinden biri olarak görülmektedir.

### 3. MATERYAL VE YÖNTEM

Bu çalışma, çilek bitkisinin verimliliğinin artırılmasına yönelik olarak, Nesnelerin İnterneti (IoT) ve yapay zeka tabanlı bir sistem aracılığıyla akıllı sera ortamında izlenmesi ve verim tahmininin gerçekleştirilmesini amaçlamaktadır. Bu kapsamda, bir prototip sera sistemi kurulmuş ve bu sisteme havalandırma, sulama ve ısıtma işlevlerini yerine getiren temel kontrol birimleri entegre edilmiştir.

Sistemin genel donanım mimarisi Şekil 3.1’de özetlenmiştir. Sera ortamındaki çevresel koşulların izlenebilmesi amacıyla sıcaklık sensörü ( $^{\circ}\text{C}$ ), nem sensörü (%), hava kalitesi sensörü, toprak nem sensörü (%), ışık şiddeti sensörü (lux) kullanılmıştır. Bu sensörler aracılığıyla toplanan veriler, kontrol sisteminin çevresel değişkenleri anlık olarak değerlendirmesine ve gerekli eylemleri (havalandırma, sulama, ısıtma) otomatik biçimde gerçekleştirmesine olanak tanımıştır.



Şekil 3.1. ESP32 tabanlı akıllı tarım otomasyon sisteminin donanım mimarisi.

Sistemde kullanılan gömülü yazılım, Arduino IDE ortamında geliştirilmiş olup ESP32 mikrodenetleyicisi için uyarlanmış Arduino çekirdeği (C/C++) temel alınmıştır.


ESP32 mikrodenetleyicisi sıcaklık, bağıl nem, ışık şiddeti, hava kalitesi ve iki farklı noktadan ölçüm alan toprak nemi sensörlerinden elde edilen verileri belirli aralıklarla okumaktadır. Okunan bu veriler doğrultusunda, önceden tanımlanmış eşik değerler ile karşılaştırma yapılarak, havalandırma fanı, sulama pompası ve ısıtıcı gibi çıkış birimlerinin devreye girip çıkması otomatik olarak kontrol edilmektedir. Ayrıca, elde edilen tüm sensör verileri, her 15 dakikada bir kablosuz ağ üzerinden Adafruit IO platformuna aktarılmaktadır. Bulut tabanlı bu yapının yanı sıra, veriler zaman bilgisi eklenmiş biçimde MicroSD kart üzerine de kaydedilmekte; böylece internet bağlantısında yaşanabilecek olası kesintilere karşı veri kaybı önlenmekte ve sistem sürekliliği sağlanmaktadır. Bu yapı sayesinde sistem, çevresel koşulları düzenli aralıklarla izleyen, kontrol birimlerini otomatik olarak tetikleyen ve aynı zamanda güvenilir bir biçimde veri kaydı yapan bütünleşik bir izleme ve kontrol altyapısı sunmaktadır.

### **3.1. Donanım Bileşenleri**

Bu bölümde, geliştirilen sera prototipinde kullanılan temel donanım bileşenleri tanımlanmaktadır.

#### **3.1.1. Kontrol Kartı**

Bu çalışmada kontrol birimi olarak, Espressif Systems tarafından geliştirilen, Wi-Fi (802.11 b/g/n) ve Bluetooth v4.2 (BLE) bağlantılarına sahip, düşük maliyetli ve yüksek performanslı bir mikrodenetleyici olan ESP32 DevKit-V1 kullanılmıştır (Şekil 3.2). Çift çekirdekli Tensilica Xtensa® LX6 mimarisi (240 MHz'e kadar saat hızı) ve entegre kablosuz haberleşme birimleri sayesinde, sensörlerden alınan verilerin hem yerel olarak işlenmesi hem de kablosuz ağ üzerinden iletilmesi tek bir kart üzerinde gerçekleştirilebilmektedir. IoT projelerinde yaygın olarak kullanılan bu platform, Arduino IDE veya MicroPython ile programlanabilmektedir.



Şekil 3.2. ESP32 Mikrodenetleyici


ESP32, entegre Wi-Fi/BLE modülleri aracılığıyla sensör verilerini doğrudan bulut platformuna aktaracak şekilde yapılandırılmıştır. Bunun yanında, verilerin sürekliliğini için ölçümler eşzamanlı olarak yerel kart üzerine de kaydedilmiştir.

### 3.1.2. Kart Modülü

Uzun süreli çevresel izleme ve taşınabilir veri toplama senaryolarında, yerel veri kaydı ve yedekleme kritik öneme sahiptir. Bu çalışmada MicroSD kart modülü, özellikle gerçek zamanlı bulut iletiminin kesintiye uğradığı durumlarda veri kaybını önlemek ve sistemin güvenilirliğini artırmak amacıyla kullanılmıştır.

Sensörlerden elde edilen ölçümler, ESP32 mikrodenetleyicisine SPI haberleşme hattı üzerinden bağlı kart modülüne, csv biçiminde düzenli olarak yazılmıştır. Böylece, hem çevrimiçi (Adafruit IO) hem de çevrimdışı (MicroSD) olmak üzere iki paralel kayıt kanalı oluşturulmuş; veri bütünlüğü ve sürekliliği önemli ölçüde güçlendirilmiştir.

ESP32 mikrodenetleyicisi 3.3V lojik seviyeleri ile çalıştığından, MicroSD modülü de doğrudan 3.3V ile beslenmiş ve bu sayede ek bir seviye dönüştürücü devreye ihtiyaç duyulmamıştır. ESP32 ile kart modülü arasındaki bağlantı yapısı ve prototip üzerindeki yerleşim düzeni Şekil 3.5'te gösterilmektedir.



Şekil 3.3. ESP32 ile MicroSD modülünün devre bağlantısı

### 3.1.3. Sıcaklık ve Nem Sensörü

Bu çalışmada çevresel sıcaklık ve bağıl nem ölçümü için DHT22 sensörü kullanılmıştır (Şekil 3.4). DHT22, nem ölçümünde polimer kaplı dielektrik bir sensör elemanı, sıcaklık ölçümünde ise NTC (Negative Temperature Coefficient) tabanlı bir sıcaklık sensörü içermekte; her iki ölçümü de tek bir veri pini üzerinden dijital olarak mikrodenetleyiciye iletmektedir. Bu sayede, harici ADC devresine ihtiyaç duyulmaksızın sıcaklık ve nem verileri, doğrudan sayısal formda elde edilebilmektedir.




Şekil 3.4. DHT22 sıcaklık-nem sensörü

Kullanılan DHT22 sensörü, yaklaşık  $-40^{\circ}\text{C}$  ile  $+80^{\circ}\text{C}$  arasındaki sıcaklıklarda ölçüm yapabilmekte ve %0 ile %100 bağıl nem aralığında veri sağlayabilmektedir. Üretici teknik dokümanına göre sıcaklık ölçüm doğruluğu yaklaşık  $\pm 0.5^{\circ}\text{C}$ , nem ölçüm doğruluğu ise  $\pm 2\% \text{RH}$  mertebesindedir. Sensör yaklaşık her 2 saniyede bir yeni ölçüm üretmekte, bu da sera içi mikroklima takibi için yeterli zaman çözünürlüğü sunmaktadır. DHT22, 3.3–6V aralığında çalışabilmekte olup, bu tez kapsamında ESP32 mikrodenetleyicisi ile uyumlu olacak şekilde 3.3V besleme gerilimiyle kullanılmıştır.

### 3.1.4. Işık Şiddeti Sensörü

Bu çalışmada ortam ışık düzeyini izlemek için BH1750 tabanlı bir ışık şiddeti sensörü kullanılmıştır (Şekil 3.5). BH1750, üzerine düşen ışığı 16-bit çözünürlüklü sayısal veriye dönüştürebilen, I<sup>2</sup>C arayüzüne sahip bir ortam ışığı (ambient light) sensörüdür. Kart üzerinde BH1750FVI entegresi bulunmakta; fotodiyot tarafından üretilen analog sinyal, entegre içinde yer alan ADC tarafından sayısallaştırılmakta ve doğrudan lux cinsinden çıktı vermektedir. Böylece harici bir ADC devresine ihtiyaç duyulmadan, mikrodenetleyici ile dijital haberleşme üzerinden ışık şiddeti ölçümleri alınabilmektedir.

Kullanılan BH1750 sensörü, yaklaşık 1–65.535lux aralığında ölçüm yapabilmekte; 16-bit dijital çıktısını tipik olarak 0x23 veya 0x5C I<sup>2</sup>C adresleri üzerinden iletmektedir. Çalışma gerilimi 3.0–5.0V aralığındadır ve aktif durumda yaklaşık 0,12mA düzeyinde düşük bir güç tüketimine sahiptir. Bu özellikleri nedeniyle, otomatik aydınlatma sistemleri ve akıllı tarım uygulamalarında yaygın biçimde tercih edilen bir sensördür.



Şekil 3.5. BH1750 ışık sensörü

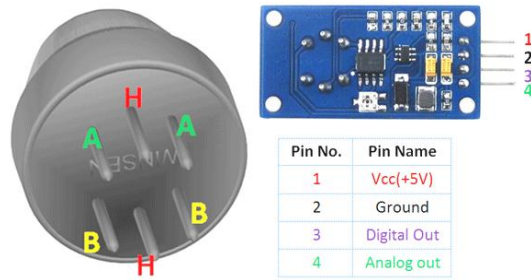
Bu tez kapsamında BH1750, çilek bitkilerinin maruz kaldığı ışık şiddetinin zaman içindeki değişimini izlemek ve daha sonra DLI (Daily Light Integral) ve ışığa bağlı diğer türetilmiş değişkenlerin hesaplanmasında kullanılmak üzere, sera içi aydınlatma düzeyini kayıt altına almak amacıyla kullanılmıştır.

### 3.1.5. Hava Kalitesi Sensörü

Bu çalışmada sera için hava kalitesini izlemek amacıyla MQ-135 tabanlı bir gaz sensörü kullanılmıştır (Şekil 3.6). Havadaki çeşitli kirleticilere duyarlı SnO<sub>2</sub> tabanlı yarıiletken bir gaz sensörüdür. Gaz konsantrasyonuna bağlı olarak sensörün iç direnci

değişmekte; bu direnç değişimi, modülün analog çıkışında gerilim değişimi şeklinde izlenmektedir.

MQ-135 sensörü; CO<sub>2</sub>, NH<sub>3</sub>, NO<sub>x</sub>, benzen, duman ve uçucu organik bileşikler (VOC) gibi bir dizi gazı algılayabilmektedir. Sensör modülü, analog gerilim çıkışı üretmekte ve bu sinyal ESP32 mikrodenetleyicinin ADC (analog-sayısal çevirici) birimi üzerinden okunmaktadır.



Şekil 3.6. MQ-135 sensör modülü

Sensörün duyarlılığı orta düzeydedir ve ölçümleri sıcaklık ve bağıl nemdeki değişimlerden etkilenebilmektedir. Bu nedenle bu çalışmada sensör, mutlak konsantrasyon tayininden ziyade hava kalitesindeki görece değişimlerin ve eğilimlerin izlenmesi amacıyla kullanılmıştır.

### 3.1.6. Toprak Nem Sensörü

Bu çalışmada, kök bölgesindeki su durumunu izlemek amacıyla iletkenlik/direnç prensibiyle çalışan bir toprak nem sensörü kullanılmıştır. Sensör, nem ölçer problemlerin ölçüm yapılacak ortama batırılmasıyla çalışmakta; ortamın su içeriği arttıkça elektriksel iletkenlik yükselmekte, buna bağlı olarak prob uçları arasındaki potansiyel fark değişmektedir. Bu gerilim değişimi, toprak nem düzeyinin görece bir göstergesi olarak yorumlanmaktadır. Kart üzerinde yer alan trimpot üzerinden sensörün hassasiyet ayarı yapılabilmektedir (Şekil 3.7).



### 3.1.8. Röle Modülü

Bu çalışmada, kontrol devresi ile çıkış birimleri (fan, pompa vb.) arasında elektriksel izolasyon sağlamak amacıyla tek kanallı 5V röle modülü kullanılmıştır (Şekil 3.9). Röle, düşük gerilimle çalışan mikrodenetleyici sistemleri ile daha yüksek gerilim ve akım gerektiren AC veya DC yüklerin güvenli şekilde kontrol edilmesine olanak tanıyan bir elektromekanik anahtarlama elemanıdır.

Röle modülü, lojik 0 (0V) seviyesi ile tetiklenmektedir. Bu, ESP32 tarafından düşük sinyal gönderildiğinde röle bobinini aktif hale getirerek bağlı olan yükü (örneğin fan) devreye alması anlamına gelir. Bu yapısı sayesinde, mikrodenetleyici sisteminin çalıştığı düşük gerilim seviyesi, yüksek gerilimli sistem bileşenlerinden elektriksel olarak izole edilmiş olur. Bu durum hem sistem güvenliği hem de donanım bütünlüğü açısından kritik öneme sahiptir.



Şekil 3.9. Röle modülü

Bu çalışmada, fan, sıcaklık 30 °C üzerine çıktığında ESP32 tarafından röle tetiklenmekte, sıcaklık 25 °C'nin altına düştüğünde ise röle bırakılarak fan durdurulmaktadır. Böylece mikrodenetleyici ile yük arasında bir anahtarlama kontrolü sağlanmıştır.

### 3.1.9. Su Pompası Motoru

Sistemde sulama işlemini gerçekleştirmek üzere, düşük güçlü DC motorlu bir mini diyaframlı su pompası kullanılmıştır. Bu amaçla tercih edilen R385 mini akvaryum pompası (Şekil 3.10), besleme gerilimine bağlı olarak düşük basınçtan daha yüksek basınca su transferi yapabilmekte ve küçük ölçekli sera uygulamaları için yeterli debiyi sağlamaktadır.



**Şekil 3.10.** Su pompası motoru

Pompa, sera içi toprak nemi sensöründen elde edilen geri bildirimle dayalı olarak otomatik şekilde kontrol edilmiştir. Toprak nemi %70'in altına düştüğünde pompa AÇIK konuma getirilmiş, nem %90 seviyesine ulaştığında ise sulama durdurularak pompa KAPALI konuma geçirilmiştir. Böylece, hem bitki kök bölgesinde aşırı kuruma ve aşırı suya boğulma durumları önlenmiş hem de su kullanımı daha verimli hale getirilmiştir.

Kullanılan R385 pompası 6–12V DC aralığında çalışmakta, yüksüz durumda yaklaşık 0,5–0,7A akım çekmekte ve yaklaşık 1,5–2L/dakika aralığında debi sağlayabilmektedir. Uygun çalışma koşullarında pompa, 2m'ye kadar emiş ve 3m'ye kadar dikey basma yüksekliğine ulaşabilmektedir.

### 3.2. Sera Prototipi

Bu çalışma kapsamında, sensör tabanlı izleme ve otomatik kontrol yapabilen bir sera prototipi tasarlanmış ve kurulmuştur. Prototip, kontrollü ortam koşullarında çilek yetiştiriciliği için hem veri toplama hem de karar destek amaçlı deneysel bir platform olarak kullanılmıştır.

#### 3.2.1. Fiziksel Tasarım

Bu çalışma kapsamında, Şekil 3.11'de gösterilen bir prototip sera sistemi tasarlanmış ve kurulmuştur. Sera iskelesinin tasarımında, bağlantı ve bazı taşıyıcı elemanlar 3B yazıcı kullanılarak PLA filamentten üretilmiştir. Ancak PLA'nın ısı dayanımının sınırlı olması nedeniyle, özellikle yaz aylarında serada ölçülen yüksek sıcaklıklar ve yer yer doğrudan güneş ışığına maruz kalma, bu parçaların zaman içinde eğilmesine ve deformasyonuna yol açmıştır.

Sistem, doğal havalandırmayı sınırlı ölçüde desteklemekle birlikte, mikrodenetleyici tarafından otomatik olarak kontrol edilen fan, ısıtıcı ped ve su pompası gibi birimlerle çevresel değişkenlerin hedef aralıklarda tutulması sağlanmaktadır. Bu yapı, kontrollü çevresel değişimlerin uygulanmasını ve dolayısıyla verim tahmini


modellerinde kullanılabilecek anlamlı ve tekrarlanabilir veri setlerinin toplanmasını sağlamıştır.



Şekil 3.11. Prototip seranın genel görünümü

Sera içine yerleştirilen sensörler aracılığıyla sıcaklık, bağıl nem, ışık, hava kalitesi ve toprak nemi parametreleri belirli aralıklarla ölçülmüş ve her bir sensörün çıktısı, sistem tarafından periyodik olarak değerlendirilmiştir. Özellikle çilek bitkisinin çevresel faktörlere duyarlılığı göz önünde bulundurulduğunda, bu tür bir kontrollü gözlem ortamı, üretim planlaması ve koşul optimizasyonu açısından bir temel sunmaktadır.

Sisteme ait elektronik bileşenlerin yerleşimi ve bağlantı yapısı Şekil 3.12’te gösterilmiştir. Tüm sensör verileri, ESP32 mikrodenetleyici üzerinden kablosuz ağ aracılığıyla Adafruit IO platformuna gerçek zamanlı olarak iletilmiş; aynı veriler, eşzamanlı biçimde tarih ve saat bilgisiyle birlikte MicroSD karta kaydedilmiştir. Bu çift yönlü kayıt sistemi, ağ bağlantısının kesilmesi durumlarında dahi veri kaybını önleyerek kayıt sürekliliğini sağlamaktadır.



Şekil 3.12. Sera devre elemanlarının prototip yerleşimi.

Sistem, genel kabul edilen eşik değerlere dayalı olarak çevresel koşullara otomatik yanıt verecek şekilde yapılandırılmıştır. Bu kontrol mekanizmasına göre:

- Sıcaklık 30 °C'nin üzerine çıktığında fan çalışmakta, sıcaklık 25 °C'nin altına düştüğünde durmaktadır.
- Sıcaklık 10 °C'nin altına indiğinde ısıtıcı ped aktif olmakta, sıcaklık 15 °C'yi geçtiğinde kapatılmaktadır.
- Toprak nemi %70'in altına düştüğünde su pompası çalışmakta, nem %90'a ulaştığında sulama sonlandırılmaktadır.

Bu eşik değerler, çevresel faktörlerin doğal dalgalanmalarına karşı sistemin kararlı çalışmasını sağlamakta ve gereksiz tetiklemeleri önlemektedir.

Sera prototipine yerleştirilen sıcaklık, nem, ışık şiddeti, hava kalitesi ve toprak nem sensörlerinden elde edilen ölçümler, mikrodenetleyici kartı üzerinden belirlenen örnekleme periyodunda otomatik olarak okunmuş ve hem yerel hafızaya hem de bulut ortamına aktarılmıştır. Sensör verileri, mikrodenetleyici ve bulut platformu (Adafruit IO) üzerinden 15 dakikalık zaman aralıklarıyla kaydedilmiştir. Her kayıt satırında zaman bilgisi ve ilgili sensörlerin anlık ölçüm değerleri bulunmaktadır.

### 3.2.2. Bulut Ortamı ve Veri Akışı

Fiziksel olarak inşa edilen sera prototipinin, yalnızca yerel ölçüm ve kontrol için değil, aynı zamanda uzaktan izleme, veri kaydı ve analiz için de kullanılabilmesi amacıyla bulut tabanlı bir veri altyapısı tasarlanmıştır. Mikrodenetleyici üzerinden okunan sensör değerleri, belirli aralıklarla internet üzerinden bulut platformuna aktarılmıştır.

Bu amaçla, IoT tabanlı uygulamalar için hem donanım hem de yazılım desteği sunan Adafruit ekosistemi tercih edilmiştir. Adafruit'in bulut hizmeti olan Adafruit IO, sensör verilerinin gerçek zamanlı olarak iletilmesi, saklanması ve görselleştirilmesi için REST API, MQTT protokolü, Dashboard (gösterge paneli) ve Feed (veri akışı) yapıları üzerinden çalışmaktadır.

Bu çalışmada sera ortamına yerleştirilen sensörlerden elde edilen sıcaklık (°C), bağıl nem (%RH), ışık şiddeti (lux) ve hava kalitesi verileri, ESP32 mikrodenetleyicisi aracılığıyla Wi-Fi üzerinden Adafruit IO platformuna 15 dakikalık örnekleme aralıklarıyla gönderilmiştir. Her bir sensör için ayrı bir feed oluşturularak, veriler dashboard üzerinde gauge, line chart ve text bileşenleri ile izlenmiştir.

Veri güvenliğini artırmak ve olası ağ kesintileri veya platform erişim sorunlarına karşı önlem almak amacıyla, tüm ölçümler aynı zamanda MicroSD kart üzerine zaman damgalı biçimde kaydedilmiştir. Böylece, bulut tabanlı izleme ile yerel veri kaydı bir arada kullanılarak hem veri bütünlüğü hem de sistem sürekliliği güvence altına alınmıştır.

### 3.2.3. Hatalı ve Eksik Verilerin Kontrolü

Hem sensör ölçümleri hem de manuel hasat kayıtları, pratik uygulama koşulları nedeniyle zaman zaman eksik, hatalı ya da fiziksel olarak tutarsız değerler içerebilmektedir. Bu nedenle, modelleme aşamasına geçilmeden önce, veri kümesinde hatalı, aykırı ve eksik gözlemler kontrol edilmiştir. Sensör verilerinde, sensör arızası veya bağlantı kopmasına işaret eden sabit veya imkansız değerler, aynı zaman damgasında birbiriyle uyumsuz kayıtlar ve kısa süreli veri kesintiler; hasat verilerinde ise tarih kaymalarına, yinelenen kayıt girişlerine ve ölçüm hatalarına yönelik kontroller yapılmıştır.

Toprak nemi sensörlerinin oksidasyona duyarlılığı nedeniyle düzensiz ve hatalı ölçümler gözlemlenmiştir. Bu nedenle, sensör güvenilirliğini artırmak ve modelleme sürecinin doğruluğunu sağlamak amacıyla çoklu sensör tutarlılığı kontrol edilmiştir. İki farklı toprak nemi sensörü arasındaki değerler karşılaştırılarak, tutarsızlık durumlarında

daha güvenilir olan referans alınmıştır. Bir sensör hatalı ise diğeri referans alındı. Her ikisi de güvensiz veya hatalı ise, ilgili günün ortalaması ile doldurulmuştur.

Sıcaklık, bağıl nem, ışık ve hava kalitesi sensörlerinde anlamlı eksik veya hatalı veri tespit edilmediği için bu seriler doğrudan kullanılmıştır.

### 3.3. Veri Setinin Oluşturulması

Sensörler ham olarak 15 dakikalık aralıklarla ölçüm yapmakta ve bu ölçümler anlık gürültü veya kısa süreli sıçramalar içerebilmektedir. Bitkinin fizyolojik tepkisi ise dakikalar düzeyindeki dalgalanmalardan ziyade saatler ve günler ölçeğinde birikimli koşullara bağlıdır. Bu nedenle 15 dakikalık ham veriden saatlik ortalama hesaplanması ve saatlik ortalamalardan günlük özet değerleri elde edilmiştir. Bu adım, sensörlerde görülebilecek ani sıçramaların, tek seferlik ölçüm hatalarının ve anlık gürültünün etkisini azaltarak, daha pürüzsüz ve yorumlanabilir bir zaman serisi elde etmeyi sağlamıştır.

Sonrasında oluşturulan saatlik seriler kullanılarak her takvim günü için minimum, maksimum, ortalama, standart sapma ve (ışık için) günlük toplam gibi özet istatistikler hesaplanmıştır. Böylece, ham veri yapısı, her sensör için tek satırla temsil edilen bir günlük özet tabloya dönüştürülmüştür.

#### 3.3.1. Hasat Verilerinin Günlük Verime Dönüştürülmesi

Çilek bitkisinde verim, tek bir günün koşullarından çok, belirli bir süre boyunca biriken fotosentez, su ve besin süreçlerinin sonucunda ortaya çıkan kümülatif bir çıktıdır. Hasat ölçümleri ise pratik nedenlerle yalnızca belirli günlerde (örneğin 3–7 günde bir) yapılmaktadır. Verimin bu şekilde düzensiz aralıklarla ölçülmesi, doğrudan modelleme yapabilmek için günlük verim serisinin yeniden oluşturulması gerekmektedir.

Bu çalışmada, hasatlar arasındaki günlerdeki verimi tahmin etmek için kütleli koruyan doğrusal kümülatif enterpolasyon (mass-preserving linear cumulative interpolation) kullanılmıştır. Temel fikir, önce kümülatif verim eğrisini tanımlayıp bunu zaman ekseninde doğrusal olarak enterpole etmek, ardından günlük verimi kümülatif eğrinin ardışık farkları olarak elde etmektir. Böylece hem toplam hasat miktarı korunmakta hem de zaman ekseninde düzgün ve monoton artan bir kümülatif eğri elde edilmektedir. Bu yaklaşım, coğrafi istatistik ve areal enterpolasyon literatüründe kullanılan pycnophylactic (kütle korumalı) enterpolasyon fikrinin zamansal bir uyarlaması olarak görülebilir (Tobler, 1979; Comber vd., 2019; Kallio vd., 2022).

Klasik doğrusal enterpolasyon verilen iki nokta  $(x_0, y_0)$ , ve  $(x_1, y_1)$ , arada bir  $x$  değeri için Eşitlik (3.1) şeklinde tanımlanır.

$$y = y_0 + \frac{(y_1 - y_0)}{(x_1 - x_0)} \cdot (x - x_0) \quad (3.1)$$

Bu klasik yöntemde, ara noktadaki değerler bu formüle göre belirlenirken, toplam verimin (tüm günlerin toplamına karşılık gelen alanın) korunacağı garanti edilmez.

**Kümülatif hasat serisi:** Ölçülen hasat noktalarını  $(t_1, H_1), (t_2, H_2), \dots, (t_K, H_K)$  olmak üzere,  $H_k, t_k$  gününde hasat edilen miktardır. Önce her hasat aralığında kümülatif hasat değeri günlere doğrusal olarak yayılır, ardından bu kümülatif serinin türevi alınarak günlük verim  $y(t)$  elde edilir. Bu yaklaşım, her bir hasat aralığı için Eşitlik (3.2) koşulunu sağlar.

$$\sum_{t=t_{k-1}+1}^{t_k} y(t) = H_k \quad (3.2)$$

Burada:

Önceki hasat günü:  $t_{k-1}$

Şimdiki hasat günü:  $t_k$

Bu aralıkta hasat edilen toplam miktar:  $H_k$

Aralıktaki günler:  $t = t_{k-1} + 1, \dots, t_k$

Yani bu aralıktaki günlük verimlerin toplamı  $H_k$  'ya eşit olmalıdır (kütle korunumu).

Daha genel bir biçimde, aralıktaki her gün için  $w(t) \geq 0$  olacak şekilde bir ağırlık tanımlansın. İlgili aralığın toplam ağırlığı Eşitlik (3.3) olsun.

$$W_k = \sum_{t=t_{k-1}+1}^{t_k} w(t) \quad (3.3)$$

Bu durumda günlük verim Eşitlik (3.4) şeklinde yazılabilir. Böyle tanımlandığında Eşitlik (3.5) eşitliği otomatik olarak sağlanır ve kütle korunmuş olur.

$$y(t) = H_k \frac{w(t)}{W_k} \quad (3.4)$$

$$\sum_{t=t_{k-1}+1}^{t_k} y(t) = H_k \quad (3.5)$$

Hasat gününde ölçülen verimi, önceki hasat ile bu hasat günü arasındaki günlere eşit olarak paylaşmak istersek, bu aralıktaki her günü,  $w(t) = 1$ , aynı ağırlığa sahip kabul etmiş oluruz. Böylece, iki hasat arasındaki toplam miktar, aradaki gün sayısına bölünerek her güne aynı günlük verim atanır. Aralıktaki tüm günlerde sabit bir değere sahiptir. Başka bir deyişle, kütleyi koruyan doğrusal kümülatif enterpolasyon bu durumda, pratikte hasat miktarının, bir önceki hasat ile ilgili hasat günü arasındaki gün sayısına bölünmesi ile aynı sonucu vermektedir.

Hasat gününde ölçülen verimin, önceki hasat ile bu hasat günü arasındaki günlere eşit olarak dağıtılması yerine, bu tezde toplam verimi koruyan ancak günler arasında eşit olmayan dağıtımlar da denenmiştir. Bu amaçla, hasat aralığındaki çevresel koşullara göre günlük verimi ağırlıklandıran, kütleyi koruyan bir dağıtım yöntemi olarak DLI (günlük ışık integrali) tabanlı ağırlıklandırma kullanılmıştır. Bu yöntemde, hasat aralığındaki günlük ışık değerleri ağırlık olarak tanımlanır.

**DLI ile ağırlıklandırma:** Her gün için tahmini ışık birikimi  $DLI(t)$  olsun. Her gün için tahmini ışık birikimi Eşitlik (3.6) şeklinde tanımlanır.

$$w(t) = DLI(t) \quad (3.6)$$

İlgili hasat miktarı  $H_k$ 'nin günlere dağıtılmasıyla elde edilen günlük verim Eşitlik (3.7) şeklinde tanımlanır.

$$y(t) = H_k \frac{w(t)}{W_k} = H_k \frac{DLI(t)}{\sum_{u=t_{k-1}+1}^{t_k} DLI(u)} \quad (3.7)$$

Bu yapı altında, DLI değeri yüksek olan günler hasadın daha büyük bir kısmını üzerine çekerken, DLI'si düşük günlerdeki verim katkısı daha küçük kalır. Tanım gereği,

aralıktaki tüm günler için  $y(t)$  değerleri toplandığında yine  $H_k$  elde edilir; dolayısıyla toplam verim (kütle) korunmuş olur.

### 3.3.2. Günlük Işık İndeksi (DLI)

Bitkilerin büyüme ve verim performansını belirleyen temel çevresel faktörlerden biri, belirli bir süre boyunca aldıkları toplam fotosentetik ışık miktarıdır. Bu toplam ışık yükü, Günlük Işık İntegrali (Daily Light Integral, DLI) ile ifade edilir ve birimi  $\text{mol m}^{-2} \text{gün}^{-1}$ 'dir. DLI, gün boyunca bitki üzerine düşen fotosentetik foton akısının zamana göre integraline karşılık gelir ve kontrollü ortam bitkiciliğinde yaygın olarak kullanılan temel bir büyüme göstergesidir. DLI'nin yetersiz olması, fotosentez hızını düşürerek büyüme ve verimi sınırlar; buna karşılık, uygun aralıkta sağlanan DLI, bitki gelişimini ve verim potansiyelini doğrudan artırır (Stallknecht, 2021; Zavafer vd., 2023).

DLI, fotosentez için kullanılabilir kümülatif ışık enerjisini ifade ettiği için, bitki büyümesi ve verimi ile doğrudan ilişkilidir (Ocampo, 2017). Yapılan çalışmalar, DLI'nin farklı büyüme aşamalarında uygun şekilde ayarlanmasının, özellikle hidroponik marul gibi ürünlerde foton verimini ve genel büyümeyi önemli ölçüde artırabildiğini göstermektedir (Yang vd., 2024).

Bitki fabrikalarında ve seralarda, özellikle doğal güneş ışığının yetersiz olduğu durumlarda, bitkilerin büyümesi için gerekli ışık düzeyi yapay aydınlatma ile ayarlanabilmektedir (Alaviani vd., 2022; Zhang vd., 2024). LED aydınlatma sistemleri, DLI'nin hassas bir şekilde kontrol edilmesine olanak tanıyarak, farklı bitki türleri ve büyüme evreleri için ışık koşullarının özelleştirilmesini sağlar (Alaviani vd., 2022).

Bitki, ışığa yalnızca anlık şiddeti üzerinden (ortalama lux değeri) değil, belirli bir süre boyunca aldığı toplam foton miktarı üzerinden biyolojik tepki verir. Başka bir deyişle, 24 saatlik bir periyotta DLI, fotosentetik foton akı yoğunluğunun (PPFD) gün boyunca integrali olarak düşünülebilir; haftalık ölçekte ise ilgili günlere ait DLI değerlerinin toplamı, o haftanın toplam ışık yükünü temsil eder.

Bu nedenle haftalık verimi açıklarken, ışığın haftalık toplamı (günlük DLI'ların toplamı ya da bunlara karşılık gelen toplam ışık yükü) ile çalışmak hem bitkinin birikimli fotosentez dinamiği hem de pratik sera yönetimi açısından daha uygundur. Nitekim literatürde de haftalık toplam ışık (DLI yaklaşımı) ile haftalık verim arasındaki ilişkinin, yalnızca ortalama lux değerlerine dayalı göstergelere göre daha güçlü ve açıklayıcı olduğu belirtilmiştir (Torres & Lopez, 2010).

### 3.3.3. Büyüme Derece Günleri (GDD)

Bitki gelişimi, belirli bir eşğin üzerindeki sıcaklıklarda biriken ısı zaman (thermal time) ile yakından ilişkilidir. Bu birikimi nicel olarak ifade etmek için en yaygın kullanılan gösterge, Büyüme Derece Günleri (GDD) kavramıdır. GDD, her ürüne özgü bir baz sıcaklığın üzerindeki günlük ısı birikiminin toplanmasıyla hesaplanır. Bu yaklaşım, verim tahmini yapmak ve hasat zamanını optimize etmek amacıyla acı biber, tatlı patates, buğday ve pirinç gibi çok farklı ürünlerde uygulanmıştır (Villordon vd., 2009; Kim vd., 2018; Liu vd., 2022; Franch vd., 2021).

GDD, sıcaklığı bitki gelişimi ile ilişkilendiren basit ama etkili bir gösterge olduğundan, verim tahmini ve tarımsal planlama için değerli bir araç olarak kullanılmaktadır. Bitkisel üretim için uygun coğrafi alanların belirlenmesine ve iklim değişikliğinin tarım üzerindeki etkisinin değerlendirilmesine de katkı sağlamaktadır (Kim & Yun, 2008; Gordon & Bootsma, 1993).

GDD, günlük ortalama sıcaklığın bitkinin gelişmeye başladığı taban sıcaklık ( $T_{base}$ ) değerini ne kadar aştığını ve bu farkın zaman içinde nasıl biriktiğini gösteren bir ölçüttür. En yaygın kullanılan günlük ortalama yönteminde, gün  $d$  için GDD Eşitlik (3.8)'deki gibi tanımlanmıştır (Penn State Extension, 2023).

$$GDD_d = \frac{T_{max,d} + T_{min,d}}{2} - T_{base} \quad (3.8)$$

Burada  $T_{max,d}$  ve  $T_{min,d}$  ilgili günün maksimum ve minimum hava sıcaklıklarını,  $T_{base}$  ise bitkinin gelişmeye başladığı taban sıcaklığı ifade etmektedir. Ortalama sıcaklık, taban sıcaklığın altında kaldığında o gün için GDD değeri sıfır kabul edilir; böylece yalnızca büyüme gerçekten katkı sağlayan ısı birikimi dikkate alınır (CFAES Weather System, 2024).

Çilek için literatürde kullanılan taban sıcaklık ( $T_{base}$ ) değerleri, çeşide, hedeflenen fenolojik evreye ve yetiştirme koşullarına bağlı olarak genellikle 3–10°C bandında yer almaktadır. Örneğin; bazı hidroponik ve kontrollü ortam çalışmalarında 3°C taban sıcaklık kullanılırken (Hernández-Martínez vd., 2023; Alvarado-Raya vd., 2021), daha genel saha ve verim çalışmaları ile büyüme modeli uygulamalarında 7°C veya 10°C taban sıcaklık değerleri rapor edilmiştir (Rosa vd., 2011).

Bu tez kapsamında, günlük GDD hesabı için öncelikle saatlik sıcaklık ölçümlerinden günlük ortalama sıcaklık ( $T_{ort}$ ) elde edilmiş, ardından taban sıcaklık  $T_b=10\text{ }^\circ\text{C}$  (Altieri vd., 2025) alınarak:  $GDD_d = \max(0, T_{ort} - T_{base})$  ile gdd değişkeni hesaplanmıştır.

### 3.3.4. Kaydırmalı Zaman Pencereleeri

Bitki verimi, çoğu zaman tek bir günün anlık koşullarının değil, belirli bir süre boyunca maruz kalınan birikimli çevresel koşulların bir sonucu olarak ortaya çıkmaktadır. Özellikle ışık, sıcaklık gibi değişkenler, birkaç günden birkaç haftaya uzanan zaman dilimlerinde birikerek bitkinin büyümesini ve meyve oluşumunu etkilemektedir.

Bu nedenle, modele girdi olarak yalnızca tek bir güne ait anlık özetlerin (günlük ortalama ya da toplam değerler) verilmesi yerine, kayan pencere (rolling window) yaklaşımı ile 7 günlük birikimli özellikler de türetilmiştir. Böylece her bir gün için, zaman içinde birikimli etkiyi yansıtan yeni öznitelikler elde edilmiştir.

Verim tahmini veri seti oluşturulurken, bu kaydırmalı pencereler hasat günlerine göre hizalanmış şekilde kullanılmıştır. Her bir hasat günü  $t_h$  için verim çıktısı, o gün ölçülen toplam hasat miktarı olarak tanımlanmıştır. Buna karşılık girdi özellikleri,  $t_h$  gününden geriye doğru tanımlanan pencereler üzerinden hesaplanmıştır.

Başka bir deyişle, her bir hasat günü için, hasattan önceki günlere ait çevresel değişkenler üzerinde kaydırmalı pencereler uygulanarak haftalık birikimli özellikler türetilmiş; böylece verim çıktısı, o hasattan önceki dönemde biriken çevresel koşullar ile ilişkilendirilmiştir.

## 3.4. Verim Tahmin Modelleri

Bu bölümde, sensör verilerinden türetilen öznitelikler kullanılarak çilek verimini tahmin etmek için kurulan makine öğrenmesi modelleri ve bu modellerin eğitimi sırasında kullanılan doğrulama stratejisi açıklanmaktadır. Çalışmanın temel amacı, haftalık verim değerlerini mümkün olduğunca yüksek doğrulukla öngörebilen ve farklı özellik kümeleri ile algoritmaların nesnel biçimde karşılaştırılmasına imkan veren bir modelleme çerçevesi oluşturmaktır.

Bu kapsamda, verim tahmini için üç farklı makine öğrenmesi algoritması kullanılmıştır: Random Forest, Gradient Boosting Regressor ve Linear Regresyon.

### 3.4.1. Lineer Regresyon

Temel kıyaslama modeli olarak standart çoklu doğrusal regresyon kullanılmıştır. Lineer regresyon, bağımlı değişken ile bağımsız değişkenler arasındaki ilişkiyi doğrusal bir kombinasyonla ifade eder ve katsayıları en küçük kareler yöntemiyle tahmin eder (Hastie, Tibshirani & Friedman, 2009).

$$\hat{y} = \beta_0 + \sum_{j=1}^p \beta_j x_j \quad (3.9)$$

Burada,  $\hat{y}$  tahmin edilen değeri,  $x_j$  giriş özelliklerini,  $\beta_j$  ise regresyon katsayılarını göstermektedir.

Lineer regresyon, giriş değişkenleri ile hedef değişken arasında doğrusal bir ilişki varsayan, yorumlanması kolay ve hesaplama açısından verimli bir modeldir. Ancak bu sadelik, özellikle tarımsal verim tahminlerinde olduğu gibi değişkenler arasındaki ilişkilerin doğrusal olmadığı veya karmaşık yapılar sergilediği durumlarda performans kısıtı oluşturabilir (Kurmi & Singh, 2025). Buna karşın, lineer regresyon; yorumlanabilirliğin ve hızın doğruluğa göre daha önemli olduğu veya hesaplama kaynaklarının sınırlı olduğu senaryolarda önemli bir araçtır (Naidu, 2024).

### 3.4.2. Random Forest

Random Forest (Rastgele Orman), eğitim sırasında birden fazla karar ağacı oluşturan ve bu ağaçların çıktılarının birleştirilmesiyle (regresyon için genellikle ortalama alınarak) tahmin üreten bir topluluk öğrenme yöntemidir. Çok sayıda giriş değişkeni içeren büyük veri kümelerini işleme konusunda özellikle etkilidir. Literatürde, Random Forest'in mahsul verimi tahmininde yüksek doğruluk ve düşük hata oranlarıyla öne çıktığı, bazı senaryolarda doğrusal regresyon ve gradyan artırma gibi diğer modellere kıyasla daha iyi performans gösterdiği belirtilmiştir (Bushara vd., 2025). Modelin doğrusal olmayan ilişkileri ve değişkenler arasındaki etkileşimleri yakalama kapasitesi, iklim ve toprak faktörleri arasındaki karmaşık etkileşimleri içeren tarımsal veriler için onu güçlü ve sağlam bir seçenek haline getirmektedir (Gupta vd., 2023).

### 3.4.3. Gradient Boosting

Gradient Boosting (Gradyan Artırma), çok sayıda sığ karar ağacını ardışık olarak bir araya getirerek güçlü bir topluluk (ensemble) model oluşturan bir yöntemdir. Temel fikir, ilk ağacın kaba bir tahmin üretmesi, sonraki ağaçların ise önceki modellerden kalan hataları (rezidüleri) adım adım azaltmaya çalışmasıdır. Böylece her adımda kayıp fonksiyonu gradyan yönünde düşürülür ve model giderek iyileştirilir. Bu yapı, doğrusal olmayan ilişkilerin ve değişkenler arası etkileşimlerin yakalanmasını mümkün kılar.

Hem mahsul verimi hem de satış tahmini bağlamlarında iyi performans gösterdiği ve genellikle Lineer Regresyon gibi daha basit modellerden daha iyi performans gösterdiği bulunmuştur. Bir satış tahmin çalışmasında, Gradient Boosting, Random Forest'ı biraz daha iyi performans göstererek sınırlı verilere sahip senaryolarda potansiyelini göstermiştir (Kang, 2023). Modelin gücü, verilerdeki karmaşık kalıpları yakalama yeteneğinde yatıyor ve bu da onu yüksek hassasiyetin gerekli olduğu görevler için uygun hale getirdiği belirtilmiştir (Kurmi & Singh, 2025).

### 3.4.4. Çapraz Doğrulama

Bu tezde, verim tahmin modellerinin genellenebilirliğini değerlendirmek için k-kat çapraz doğrulama kullanılmıştır. Çapraz doğrulama, özellikle veri setinin sınırlı olduğu durumlarda, modelin doğruluk ve genelleme performansını önyargısız biçimde tahmin etmek için istatistik ve makine öğrenmesi literatüründe yaygın olarak kullanılan bir yaklaşımdır (Arlot & Celisse, 2010; Kohavi, 1995).

K-kat çapraz doğrulama, veri kümesi önce rastgele karıştırılmış, ardından yaklaşık eşit büyüklükte k-katmana (fold) ayrılmıştır. Her iterasyonda bu katmanlardan biri doğrulama kümesi, kalan k-1 katman ise eğitim kümesi olarak kullanılmıştır. Böylece her gözlem, tam olarak bir kez doğrulama kümesi içinde yer almış; k iterasyon sonunda tüm gözlemler için birer tahmin elde edilmiştir. Bu düzenleme, modelin genel istatistiksel genellenebilirliğini ve veri uzayının tamamı üzerindeki ortalama performansını değerlendirmeyi amaçlamaktadır (Kohavi, 1995; Yates vd., 2023).

Beş katlı çapraz doğrulama, modellerin eğitim verisine aşırı uyum göstermesini engellemeye yardımcı olduğu ve görülmemiş veriler üzerindeki performansa dair daha güvenilir bir tahmin sağladığı için verim tahmini çalışmalarında da yaygın biçimde kullanılmaktadır (Drummond vd., 2003). Kenduiywo ve ark. (2020), MODIS verilerini kullanarak mısır verimini tahmin etmek için Destek Vektör Regresyonu ve Random

Forest modellerini 5 katlı yıllık çapraz doğrulama ile değerlendirmiş ve her iki model için de umut verici  $R^2$  değerleri bildirmiştir. Benzer şekilde, Thorp ve ark. (2005) CERES-Mısır büyüme modelini doğrularken çapraz doğrulama yaklaşımını kullanmış ve model parametrelerinin kalibrasyonu ile farklı iklim koşullarındaki performansın değerlendirilmesinde çapraz doğrulamanın önemini vurgulamıştır.

### 3.4.5. Değerlendirme Ölçütleri

Bu çalışmada, verim tahmin modellerinin nicel performansını değerlendirmek ve modelleri birbiriyle karşılaştırmak için, regresyon problemlerinde yaygın olarak kullanılan üç temel ölçüt kullanılmıştır: determinasyon katsayısı ( $R^2$ ), Ortalama Mutlak Hata (MAE) ve Kök Ortalama Kare Hatası (RMSE). Bu göstergeler hem klasik istatistik literatüründe hem de makine öğrenmesi ve tahminleme çalışmalarında standart değerlendirme ölçütleri olarak kabul edilmektedir (Montgomery, Peck & Vining, 2012).

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3.10)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3.11)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3.12)$$

Burada

$y_i$ :  $i$ 'inci gözleme ait gözlenen (gerçek) verim değeri,

$\hat{y}_i$ :  $i$ 'inci gözlem için model tarafından tahmin edilen verim değeri,

$\bar{y}$ : tüm gözlemler için ortalama gözlenen verim,

$n$ : toplam gözlem sayısını ifade etmektedir.

Model karşılaştırmalarında,  $R^2$  değerinin yüksek; MAE ve RMSE değerlerinin düşük olması, ilgili modelin verim tahmini açısından daha iyi performans gösterdiği şeklinde yorumlanmıştır. Bu tür bir karşılaştırmalı değerlendirme yaklaşımı, farklı regresyon ve tahminleme modellerinin performans analizinde literatürde de yaygın olarak kullanılmaktadır.

#### 4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Bu bölümde, geliştirilen akıllı sera prototipinden (Şekil 4.1) elde edilen sensör verileri ile bu verilere dayalı olarak kurulan verim tahmin modellerinin sonuçları sunulmakta ve tartışılmaktadır.

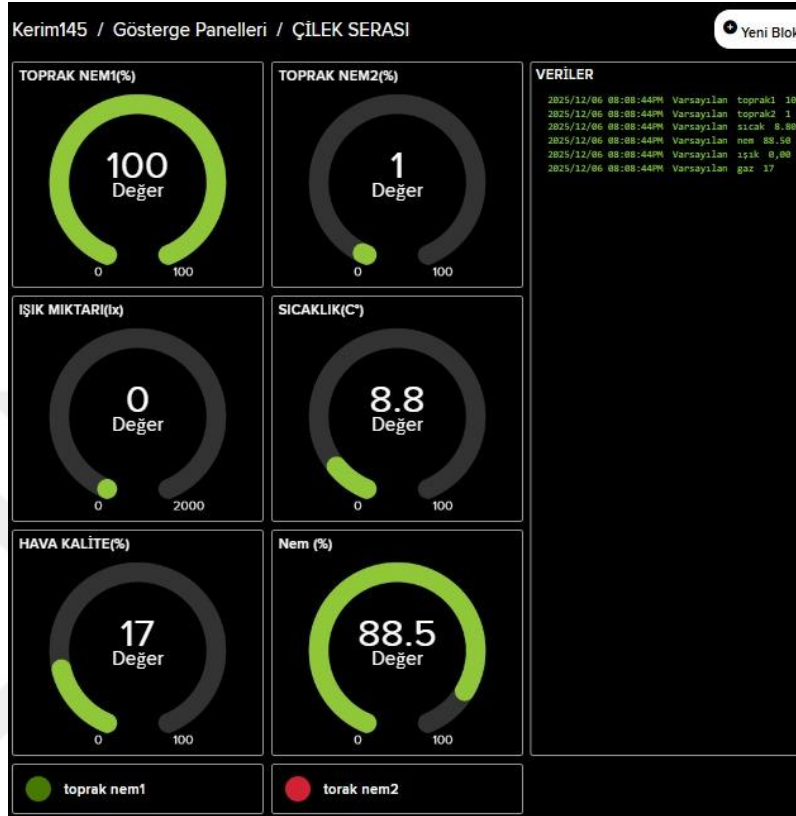
Veri toplama süreci Nisan 2025 ile Ağustos 2025 tarihleri arasında gerçekleştirilmiştir. Tahmin modellerinde kullanılan veri seti, çilek hasadının başladığı tarihten itibaren elde edilen sensör ve hasat kayıtları esas alınarak oluşturulmuştur. Tüm veri işleme, analiz ve modelleme adımları Python programlama dili kullanılarak gerçekleştirilmiştir.



Şekil 4.1. Oluşturulan akıllı sera prototipi

Geliştirilen sistem, sera ortamında meydana gelen anlık çevresel değişimlerin görselleştirilmesine ve sistemin bu değişimlere verdiği tepkilerin gerçek zamanlı olarak izlenmesine olanak sağlamaktadır. Sensörlerden elde edilen sıcaklık, bağıl nem, toprak nemi, ışık şiddeti ve hava kalitesi verileri, IoT tabanlı bir bulut platformu üzerinden anlık olarak takip edilebilmektedir.

Toprak nemi sensörünün uzun süreli kullanımda oksidasyona bağlı olarak hatalı ölçüm üretme olasılığı dikkate alınmış; bu durumu tespit edebilmek amacıyla hata kontrol ve bildirim mekanizması bulut ortamına entegre edilmiştir (Şekil 4.2).




Şekil 4.2. Adafuit IO platformu üzerinde sensör değerlerinin anlık gösterimi

Bu kapsamda, öncelikle sistemden toplanan sensör ve hasat verilerinin zaman içerisindeki davranışı analiz edilmiş; ardından bu verilerden türetilen özellikler kullanılarak oluşturulan verim tahmin modellerinin performansları değerlendirilmiştir. Elde edilen sonuçlar, model doğruluğu ve sera koşullarının bitki verimi üzerindeki etkileri açısından yorumlanmıştır.

#### 4.1. Verilerin Analizi

Sistemin başlangıç dönemine ait ilk 500 kaydın zaman serisi grafikleri kullanılarak sıcaklık, bağıl nem, ışık şiddeti, hava kalitesi ve toprak nemi değerlerinin gün içi değişimleri birlikte gösterilmiştir (Şekil 4.3).

Çoklu Sensör Verileri Dashboard  
(Saatlik Ortalama + İstatistikler)



Şekil 4.3. Çoklu sensör verilerinin zaman serisi gösterimi (ilk 500 kayıt).

Zaman serisi grafikleri incelendiğinde, ışık şiddetinin gündüz saatlerinde belirgin biçimde yükseldiği, bu artışa paralel olarak sıcaklık değerlerinin de arttığı gözlemlenmiştir. Toprak nemi serilerinde, sulama olaylarını takip eden ani artışlar ve sonrasında bu suyun bitki tarafından kullanımı ve buharlaşma süreçlerine bağlı olarak kademeli azalmalar görülmüştür. Hava kalitesi sensöründen elde edilen değerlerde ise, iç ortam havalandırma ve dış ortam koşullarına bağlı dalgalanmalar izlenmiş; bu sayede, fan hareketleri ve kapalı ortam birikimlerinin etkileri görece olarak gözlemlenebilmiştir.

Ham veriler 15 dakikalık örnekleme aralığında toplandığından, modelleme sürecinde daha kararlı ve yorumlanabilir bir yapı elde etmek amacıyla veriler günlük düzeyde özetlenmiştir. Bu kapsamda, her bir gün için sıcaklık, bağıl nem, toprak nemi, ışık ve hava kalitesi sensörlerinin gün içi ortalama, minimum, maksimum ve standart sapma değerleri hesaplanmıştır (Tablo 4.1). Günlük ortalamalar oluşturulurken önce aynı

güne ait 15 dakikalık ölçümlerden saatlik ortalamalar alınmış, ardından bu saatlik değerlerin ortalaması kullanılarak çok kısa süreli ani dalgalanmaların etkisi azaltılmıştır.

**Tablo 4.1.** Sensör verilerinin istatistik özet değerleri

<b>Değişken</b>	<b>min</b>	<b>max</b>	<b>mean</b>	<b>std</b>
<b>Toprak (%)</b>	83,385	100	95,350	3,807
<b>Gaz</b>	9,7291	36,270	16,978	4,624
<b>Sıcaklık (°C)</b>	12,320	33,607	24,167	4,7643
<b>Nem (%RH)</b>	20,326	93,493	44,542	19,867
<b>Işık (lux)</b>	132,58	3863,781	2063,224	1214,562


Tablo 4.1 incelendiğinde, sıcaklık ve ışık değişkenlerinde günler arasında geniş bir aralıkta değişim olduğu, bağıl nemde ise yüksek bir standart sapma ile önemli dalgalanmalar yaşandığı görülmektedir. Toprak neminin ise büyük ölçüde yüksek seviyelerde tutulduğu, buna rağmen sulama, kuruma döngüleri nedeniyle belli bir oynaklık sergilediği anlaşılmaktadır.

Çalışma süresince elde edilen çilek hasatlarına ait örnek görüntüler Şekil 4.4'te gösterilmiştir. Elde edilen ürün miktarları düzenli aralıklarla tartılmış ve her hasat için tarih bilgisiyle birlikte gram cinsinden kaydedilmiştir.



Şekil 4.4. Seradan elde edilen çilek hasatlarına ait görüntüler

Gerçekleştirilen hasat işlemlerine ait günlük toplam verim değerlerinin zamana bağlı değişimi Şekil 4.5’de gösterilmektedir. Hasat miktarının haziran ayı ortalarında en yüksek seviyeye ulaştığı, temmuz ayından itibaren ise sıcaklık ve ışık koşullarındaki değişimlere bağlı olarak azalma eğilimi gösterdiği gözlemlenmiştir.



Şekil 4.5. Hasat miktarının zamana göre dağılımı

Çalışma süresince gerçekleştirilen hasatlara ait özet istatistikler Tablo 4.2’te verilmiştir. Toplam hasat miktarı 16,18 kg olup, bu miktar sezon boyunca 18 ayrı hasat gününde elde edilmiştir. Hasat yapılan günlerde ortalama günlük verim 899g olarak hesaplanmış, en düşük günlük hasat 54g, en yüksek günlük hasat ise 1.671g olarak gerçekleşmiştir.

Tablo 4.2. Çalışma süresince elde edilen çilek hasatlarına ait özet istatistikler.

Metrik	Değer
Toplam hasat	16,18 kg (12 adet fide)
Hasat günleri	18 gün
Ortalama	899 g
Min–Max	54 – 1.671 g
Standart sapma	505 g

Verim değerleri, çevresel değişkenlerle zaman uyumunun sağlanabilmesi amacıyla interpolasyon yaklaşımlarından yararlanarak günlük düzeye indirgenmiştir. Benzer enterpolasyon tabanlı zaman çözünürlüğü dönüştürme yöntemleri, çilek verim tahmini çalışmalarında haftalık verim serilerinin oluşturulmasında (Maskey vd., 2019) ve ürün simülasyonlarında aylık iklim verilerinden günlük serilerin türetilmesinde (Soltani vd., 2004) kullanılmaktadır.

## 4.2. Verim Tahmini

Bitkinin yedi gün boyunca maruz kaldığı birikimli çevresel koşullar ile aynı dönemde elde edilen verim arasındaki ilişkiyi modelleyen bir regresyon problemi tanımlanmıştır. Modelin giriş vektörü, yedi günlük pencere için hesaplanan DLI ve GDD birikim değerleri ile aynı pencereye ait sensör verilerinin ortalama değerlerinden oluşturulmuş; çıktı değişkeni olarak ise bu pencereye karşılık gelen yedi günlük toplam hasat verimi kullanılmıştır.

Literatürdeki örneklerde günlük veya haftalık enterpolasyon (Snyder vd., 1996; Marino vd., 2019) yoluyla elde edilen veriler üzerinden tahmin modelleri oluşturulurken gerçek zamanlı çevresel veri setiyle eş zamanlı olarak manuel toplanan günlük hasat verileri birleştirilmiştir (Maskey vd., 2019).

Model karşılaştırmalarında, tüm algoritmalar için 5-katlı çapraz doğrulama kullanılmıştır. Veri seti yaklaşık eşit büyüklükte beş alt kümeye ayrılmış; her iterasyonda dört kat eğitim, bir kat test verisi olarak kullanılmıştır. Böylece her bir gözlem bir kez test, dört kez eğitim sürecine katkı sunmuştur. Performans değerlendirmesinde Her bir kat için,  $R^2$  ve hata metrikleri hesaplanarak ortalamaları Tablo 4.3 ve Tablo 4.4 de verilmiştir.

**Tablo 4.3.** Lineer dağıtılan verim için tahmin modellerinin performansları

Model	$R^2$	$R^2\_std$	RMSE	MAE
Lineer Regresyon	0.864	0.06	311	249
Random Forest	0.906	0.13	254	180
Gradient Boosting	0.911	0.07	230	153

Lineer dağıtılan günlük verim serisi kullanıldığında (Tablo 4.3), modellerin haftalık verimi oldukça iyi açıkladığı görülmektedir: Lineer regresyon için ortalama  $R^2$  0.86, Random Forest ve Gradient Boosting için 0.91'dir. Bu sonuçlar, topluluk temelli yöntemlerin doğrusal modele kıyasla daha düşük hata ve daha yüksek açıklama gücüne sahip olduğunu göstermektedir. DLI ağırlıklandırılmış günlük verim serisi kullanıldığında (Tablo 4.4) ise tüm modellerde belirgin bir iyileşme gözlenmektedir.  $R^2$  değeri 0.93 düzeyine çıkmaktadır. Buna karşılık RMSE ve MAE değerleri tüm modellerde azalmıştır. Ayrıca DLI ağırlıklandırılmış seride  $R^2$  standart sapmalarının daha düşük olması, modellerin katlar arasında daha kararlı bir performans sergilediğine işaret etmektedir.

**Tablo 4.4.** DLI ile ağırlıklandırılmış verim için tahmin modellerinin performansları.

Model	5-kat CV				10-kat CV			
	R <sup>2</sup>	R <sup>2</sup> _std	RMSE	MAE	R <sup>2</sup>	R <sup>2</sup> _std	RMSE	MAE
Lineer Regresyon	0.866	0.019	293.94	229.34	0.861	0.0656	285.25	228.69
Random Forest	0.930	0.043	199.53	148.44	0.929	0.071	187.47	141.83
Gradient Boosting	0.929	0.036	201.89	132.12	0.937	0.062	179.29	124.99

DLI-ağırlıklı günlük verim için doğrusal regresyon, Random Forest ve Gradient Boosting modelleri 5-kat ve 10-kat çapraz doğrulama ile değerlendirilmiştir (Tablo 4.4). 5-kat CV’de Random Forest ve Gradient Boosting modelleri R<sup>2</sup> değeri 0.93 düzeyine ulaşırken, 10-kat CV’de en yüksek performans Gradient Boosting modeliyle elde edilmiş (R<sup>2</sup> ≈ 0.94), doğrusal regresyon ise her iki doğrulama stratejisinde de R<sup>2</sup> ≈ 0.86 civarında kalmıştır. Bu sonuçlar, DLI-ağırlıklı verim serisi üzerinde doğrusal olmayan ağaç tabanlı yöntemlerin uygun model olduğunu göstermektedir.

Bu çalışmada elde edilen sonuçlar, sera içi sıcaklık, nem, toprak nemi, ışık ve hava kalitesi gibi mikroiklim değişkenlerinin çilek verimindeki değişimin büyük bir kısmını açıklayabildiğini göstermektedir. Lineer dağıtılan verim serisi kullanıldığında bile doğrusal regresyon için 0.86, topluluk tabanlı modeller için ise 0.91 değerlerine ulaşılması, verim ile çevresel koşullar arasındaki ilişkinin güçlü olduğuna işaret etmektedir. DLI ile ağırlıklandırılmış verim serisinde R<sup>2</sup> değerlerinin 0.94’e kadar yükselmesi ise ışık birikiminin çilek verimi açısından önemli bir değişken olduğunu ve literatürde GDD/DLI temelli yaklaşımlarla uyumlu olduğunu göstermektedir (Villordon vd., 2009; Kim vd., 2018; Franch vd., 2021).

Model karşılaştırmaları, doğrusal regresyona kıyasla Random Forest ve Gradient Boosting gibi topluluk yöntemlerinin, daha yüksek R<sup>2</sup> ve daha düşük RMSE/MAE değerleriyle haftalık verimi daha iyi tahmin ettiğini göstermiştir. Bu sonuç, verim ile çevresel değişkenler arasındaki ilişkinin tam olarak doğrusal olmadığını ve karar ağaçlarına dayalı yöntemlerin değişkenler arası etkileşimleri daha iyi yakalayabildiğini göstermektedir. Benzer biçimde, tarımsal verim tahmini çalışmalarında da ağaç tabanlı ve diğer makine öğrenmesi yöntemlerinin klasik doğrusal modellere göre genellikle daha iyi performans verdiği bildirilmiştir (Kenduiwo vd., 2020; Drummond vd., 2003). Bu tezde 5 katlı çapraz doğrulama kullanılması ise sınırlı veri seti koşullarında modellerin genellenebilirliğinin daha güvenilir biçimde değerlendirilmesine olanak sağlamıştır (Arlot & Celisse, 2010; Kohavi, 1995).

Öte yandan, veri setinin tek sezona ve sınırlı sayıda haftalık gözleme ait olması, elde edilen modellerin farklı iklim koşulları, çeşitler veya üretim ölçeklerine doğrudan genellenmesini sınırlandırmaktadır. Kaydırmalı pencerelerle tanımlanan yedi günlük DLI ve GDD birikimleri, verimin kısa vadeli iklimsel koşullara tepkisini yansıtmakta başarılı görünse de dış çevre koşulları ve besin yönetimi gibi ek değişkenlerin modele eklenmesiyle açıklayıcılığın artırılması mümkündür (Altieri vd., 2025; Lopez & Runkle, 2014).



## 5. SONUÇLAR VE ÖNERİLER

Bu tez kapsamında, çilek yetiştiriciliği için küçük ölçekli bir akıllı sera prototipi başarıyla oluşturulmuştur. Sıcaklık, bağıl nem, toprak nemi, ışık şiddeti ve hava kalitesi sensörlerinden sürekli veri toplayan ESP32 tabanlı bir IoT sistemi, verilerin çevrimiçi olarak izlenmesini sağlamış ve fan, ısıtıcı ile sulama pompasını önceden tanımlanan eşiklere göre otomatik olarak kontrol etmiştir. Böylece gerçek zamanlı izleme, sensör verilerinde anomali takibi ve temel otomasyon işlevleri, tek bir entegre ve uygun maliyetli platformda bir araya getirilmiş; sera ortamının geleneksel yöntemlere göre daha etkin yönetilebilecektir.

Toplanan çok değişkenli verilerden günlük ve haftalık özet istatistikler ile DLI ve GDD gibi göstergeler üretilmiş; düzensiz hasat kayıtları, kütle korunumlu enterpolasyon ve DLI tabanlı ağırlıklandırma ile düzenli günlük ve haftalık verim serilerine dönüştürülmüştür. Bu seriler kullanılarak kurulan makine öğrenmesi modelleri arasında Gradient Boosting algoritması yaklaşık  $R^2$  değeri yaklaşık 0.94 ile en başarılı sonuçları vermiş, haftalık verim ile sera mikroiklimi arasındaki ilişkinin güvenilir biçimde modellenebileceğini göstermiştir.

Dış hava durumu gibi ek değişkenlerin modele dahil edilmesiyle tahmin doğruluğunun artırılması mümkündür. Ayrıca geliştirilen verim tahmin modellerinin öngörüye dayalı dinamik kontrol stratejileri ile birleştirilmesi hem verimi artıracak hem de kaynak kullanımını daha da iyileştirecektir. Görüntü işleme, IoT ve yapay zeka tabanlı erken uyarı mekanizmalarının eklenmesiyle, sensör verilerindeki anomali ve olası hastalık işaretlerinin erken tespiti sağlanarak verim kayıplarının önüne geçilebileceği değerlendirilmektedir. Bu tür geliştirmelerle, sunulan akıllı sera prototipinin yalnızca izleme ve tahmin aracı olmaktan çıkıp, proaktif bir yönetim sistemi haline gelmesi mümkün olacaktır.

## 6. KAYNAKLAR

- Adediran, A. A., Onu, P., Adesoye, A. T., Emmanuel, A., & Oguntayo, S. A. (2024). Use of IoT for sustainable agriculture. *International Conference on Science, Engineering and Business for Driving Sustainable Development Goals (SEB4SDG)*. <https://doi.org/10.1109/SEB4SDG60871.2024.10630149>
- Alaviani, S. S., Iersel, M. W. van, & Velni, J. M. (2022). Optimal supplemental lighting control for an extended photoperiod in controlled environment agriculture. *Advances in Control and Optimization of Dynamical Systems*. <https://doi.org/10.1016/j.ifacol.2022.11.254>
- Altieri, G., Curcio, D., Lepore, A., Grobler, E., Maffia, A., Gargano, N., Tedesco, A., Graziano, M. L., Mazzei, P., Capocasa, F., Mezzetti, B., & Celano, G. (2025). Yield and quality of new strawberry advanced breeding selections and commercial cultivars, grown under warm -temperate climatic conditions. *Agriculture*, *15*(13), 1406. <https://doi.org/10.3390/agriculture15131406>
- Alvarado-Raya, H. E., Vázquez-Rodríguez, J. C., Ramírez-Arias, A., Calderón-Zavala, G., & Rivera-del-Río, R. (2021). Phenology and growing degree days of Festival strawberry grown on red volcanic rock at two plant densities. *Revista Fitotecnia Mexicana*, *44*(3), 349–356.
- Arlot, S., & Celisse, A. (2010). A survey of cross-validation procedures for model selection. *Statistics Surveys*, *4*, 40–79. <https://doi.org/10.1214/09-SS054>
- Benyezza, H., Bouhedda, M., Kara, R., & Rebouh, S. (2023). Smart platform based on IoT and WSN for monitoring and control of a greenhouse in the context of precision agriculture. *Internet of Things*, *23*, 100830. <https://doi.org/10.1016/j.iot.2023.100830>
- Bhardwaj, S., Venkatesan, S., Rawat, S., & Nath, P. (2024). Transforming Agriculture with IoT for Precision Agriculture and Sustainable Crop Management. *The Future of Agriculture: IoT, AI and Blockchain Technology for Sustainable Farming* <https://doi.org/10.2174/9789815274349124010012>
- Bushara, A. R., T., A., & S., F. (2025). Optimizing crop yield forecasting with ensemble machine learning techniques. *International Journal of Science and Research Archive*. <https://doi.org/10.30574/ijrsra.2025.14.1.0189>
- CFAES Weather System. (2024). CFAES Weather System: GDD and precipitation calculator. *College of Food, Agricultural, and Environmental Sciences*, The Ohio State University. <https://weather.cfaes.osu.edu/>
- Comber, A., Proctor, J., & Anthony, S. (2019). Spatial interpolation using areal features: A review of methods and opportunities using new forms of data with coded illustrations. *Geography Compass*, *13*(10), e12465. <https://doi.org/10.1111/gec3.12465>
- Del-Coco, M., Leo, M., & Carcagni, P. (2024). Machine learning for smart irrigation in agriculture: How far along are we? *Information*, *15*(6), 306. <https://doi.org/10.3390/info15060306>

- Dharani, M. K., Bharathi, M. V., & Praveena, K. (2022). Intelligent IoT-based greenhouse monitoring and control system. *I-Manager's Journal of Electronics Engineering*. <https://doi.org/10.26634/jele.12.4.19061>
- Drummond, S. T., Sudduth, K. A., Joshi, A., Birrell, S. J., & Kitchen, N. R. (2003). Statistical and neural methods for site-specific yield prediction. *Transactions of the ASABE*. <https://doi.org/10.13031/2013.12541>
- Eriş, H., Çeliktöpez, E., Çevik, U., & Kapur, B. (2022). Seralar için tam otomatik Iot tabanlı sulama sistemi tasarımı. *Çukurova Üniversitesi Mühendislik Fakültesi Dergisi*. <https://doi.org/10.21605/cukurovaumfd.1190306>
- Franch, B., Vermote, E., Skakun, S., Santamaría-Artigas, A., Kalecinski, N. I., Roger, J.-C., Becker-Reshef, I., Barker, B., Sobrino, J. A., & Justice, C. O. (2021). Forecasting Wheat Yield Using Remote Sensing: The ARYA Forecasting System. *International Geoscience and Remote Sensing Symposium*. <https://doi.org/10.1109/IGARSS47720.2021.9554274>
- Gordon, R., & Bootsma, A. (1993). Analyses of growing degree-days for agriculture in Atlantic Canada. *Climate Research*. <https://doi.org/10.3354/CR003169>
- Gupta, I., Ayalasomayajula, S., Shashidhara, Y., Kataria, A., Shashidhara, S., Kataria, K., & Undurti, A. (2023). Innovations in agricultural forecasting: a multivariate regression study on global crop yield prediction. *arXiv.Org*. <https://doi.org/10.48550/arxiv.2312.02254>
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The elements of statistical learning: Data mining, inference, and prediction* (2nd ed.). Springer.
- Haziq, M., Pang, W. L., Chan, K. Y., Lee, I. E., Chung, G. C., & Wong, S. K. (2022). High-efficiency low-cost smart IoT agriculture irrigation, soil's fertility and moisture controlling system. *Universal Journal of Agricultural Research*, 10(6), 785–793. <https://doi.org/10.13189/ujar.2022.100616>
- Hernández-Martínez, N., et al. (2023). Model development of the phenological cycle from flower to fruit of strawberries (*Fragaria* × *ananassa*). *Agronomy*, 13(10), 2489. <https://doi.org/10.3390/agronomy13102489>
- Kallio, M., Guillaume, J. H. A., Burek, P., Tramberend, S., Smilovic, M., Horton, A. J., & VIRRANTAU, K. (2022). Unpacking dasymetric modelling to correct spatial bias in environmental model outputs. *Environmental Modelling & Software*, 157, 105511. <https://doi.org/10.1016/j.envsoft.2022.105511>
- Kang, R. (2023). Sales prediction of big mart based on linear regression, random forest, and gradient boosting. *Advances in Economics, Management and Political Sciences*. <https://doi.org/10.54254/2754-1169/17/20231094>
- Kenduiywo, B. K., Ghosh, A., Hijmans, R. J., & Ndungu, L. (2020). Maize yield estimation in Kenya using modis. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. <https://doi.org/10.5194/ISPRS-ANNALS-V-3-2020-477-2020>

- Kim, Jin-Hee, & Yun, Jin I. (2008). On mapping growing degree-days (GDD) from monthly digital climatic surfaces for south Korea. *Korean Journal of Agricultural and Forest Meteorology*, 10(1), 1–8. <https://doi.org/10.5532/KJAFM.2008.10.1.001>
- Kim, S. K., Lee, J. H., Lee, H. J., Lee, S., Mun, B., An, S., & Lee, H. S. (2018). Development of prediction growth and yield models by growing degree days in hot pepper. *Protected Horticulture and Plant Factory*, 27(4), <https://doi.org/10.12791/KSBEC.2018.27.4.424>
- Kohavi, R. (1995). A study of cross-validation and bootstrap for accuracy estimation and model selection. In *Proceedings of the 14th International Joint Conference on Artificial Intelligence (IJCAI)*, 1137–1143
- Liu, L.-W., Lu, C., Wang, Y.-M., Lin, K. H., Ma, X. X., & Lin, W.-S. (2022). Rice (*oryza sativa* L.) growth modeling based on growth degree day (GDD) and artificial intelligence algorithms. *Agriculture*. <https://doi.org/10.3390/agriculture12010059>
- Mansoor, S., Iqbal, S., Popescu, S. M., Kim, S. L., Chung, Y. S., & Baek, J.-H. (2025). Integration of smart sensors and IoT in precision agriculture: Trends, challenges and future perspectives. *Frontiers in Plant Science*, 16, 1587869. <https://doi.org/10.3389/fpls.2025.1587869>
- Maskey, M. L., Pathak, T. B., & Dara, S. K. (2019). Weather Based Strawberry Yield Forecasts at Field Scale Using Statistical and Machine Learning Models. *Atmosphere*, 10(7), 378. <https://doi.org/10.3390/atmos10070378>
- Miller, T., Mikiciuk, G., Durlík, I., Mikiciuk, M., Łobodzińska, A., & Śnieg, M. (2025). The IoT and AI in agriculture: The time is now—A systematic review of smart sensing technologies. *Sensors*, 25(12), 3583. <https://doi.org/10.3390/s25123583>
- Montgomery, D. C., Peck, E. A., & Vining, G. G. (2012). *Introduction to linear regression analysis* (5th ed.). Wiley.
- Naidu, B. N. (2024). Harvest Harmony: Integrating Linear and Nonlinear Machine Learning Models for Precision Crop Recommendation. *Communications on Applied Nonlinear Analysis*, 32(1). <https://doi.org/10.52783/cana.v32.2346>
- Noureddine, S., Mohammed, B., & Abdelmadjid, M. K. (2024). Smart technology-based microclimate control system for greenhouse. *Studies in Engineering and Exact Sciences*. <https://doi.org/10.54021/seesv5n2-425>
- Ocampo, A. L. P. de. (2017). Development of Data Acquisition Model for Daily Light Integral Measurement. *Asia Pacific Higher Education Research Journal (APHERJ)*, 4(2). <https://doi.org/10.56278/apherj.v4i2.559>
- Penn State Extension. (2023). Understanding growing degree days. *Penn State College of Agricultural Sciences*. <https://extension.psu.edu/understanding-growing-degree-days>

- Pinto, R., Patil, D., Joseph, N., & Barreto, C. (2024). Smart agriculture using IoT. *International Journal for Multidisciplinary Research*. <https://doi.org/10.36948/ijfmr.2024.v06i03.19831>
- Raj, M., & Prahadeeswaran, M. (2025). Revolutionizing agriculture: A review of smart farming technologies for a sustainable future. *Discover Applied Sciences*, 7, 937. <https://doi.org/10.1007/s42452-025-07561-6>
- Rodríguez, M., et al. (2021). IoT applications for smart agriculture: A survey. *IEEE Access*, 9, 114920–114947.
- Rosa, H. T., Walter, L. C., Streck, N. A., Andriolo, J. L., Silva, M. R., & Langner, J. A. (2011). Base temperature for leaf appearance and phyllochron of selected strawberry cultivars in a subtropical environment. *Bragantia*, 70(4), 939–945. <https://doi.org/10.1590/S0006-87052011000400029>
- Sahu, K., & Mazumdar, S. G. (2012). Digitally Greenhouse Monitoring and Controlling of System based on Embedded System. *International Journal of Scientific & Engineering Research*, 3(1).
- Sales, V. H. G. (2025). Sustainably powered system designed to transform food production and foster self-sustaining societies with artificial intelligence. *Monografia-Faculdade Pitágoras de Contagem*. <https://doi.org/10.29327/41482450>
- Singh, K., & Hota, M. K. (2022). Design of low cost IoT enabled greenhouse control system for precision agricultural research application. *IOP Conference Series: Materials Science and Engineering*, 1272, 012004. <https://doi.org/10.1088/1757-899X/1272/1/012004>
- Singh, M., Ayyub, S., Sharma, D., Prasad, V., Ranadive, A., Sharma, S., Patidar, V., & Kumar, S. (2025). Sustainability through connectivity: IoT influence on agriculture. *Journal of Computer Science*. <https://doi.org/10.3844/jcssp.2025.96.110>
- Snyder, R., Spano, D., & Pawu, K. (1996). Surface renewal analysis for sensible and latent heat flux density. *Boundary-Layer Meteorology*, 77, 249–266.
- Soltani, A., Meinke, H., & de Voil, P. (2004). Assessing linear interpolation to generate daily radiation and temperature data for use in crop simulations. *European Journal of Agronomy*, 21(2), 133–148. [https://doi.org/10.1016/S1161-0301\(03\)00044-3](https://doi.org/10.1016/S1161-0301(03)00044-3)
- Stallknecht, E. (2021). Calculating and using Daily Light Integral (DLI): An introductory guide (SPES-720). *Virginia Cooperative Extension*.
- Sun, L., et al. (2022). Precision agriculture and IoT-based smart greenhouses: Trends and future directions. *Sensors*, 22(15), 5663.
- Tatlas, N. A., Ballios, D., Potirakis, S. M., Charitou, C., Koutroubinas, S., & Rangoussi, M. (2015). A smart sensor platform for greenhouse applications. *Key Engineering Materials*. <https://doi.org/10.4028/WWW.SCIENTIFIC.NET/KEM.644.92>

- Thorp, K. R., Batchelor, W. D., & Paz, J. O. (2005). A cross validation approach to evaluate ceres-maize simulations of corn yield spatial variability. *American Society of Agricultural and Biological Engineers*, <https://doi.org/10.13031/2013.19052>
- Tobler, W. R. (1979). Smooth pycnophylactic interpolation for geographical regions. *Journal of the American Statistical Association*, 74(367), 519–530. <https://doi.org/10.1080/01621459.1979.10481647>
- Torres, A. P., & Lopez, R. G. (2010). Measuring daily light integral in a greenhouse. *Purdue Extension*. <https://www.extension.purdue.edu/extmedia/HO/HO-238-W.pdf>
- Vijayaraja, L., Dhanasekar, R., Kesavan, R., Tamizhmalar, D., Premkumar, R., & Saravanan, N. (2022). A cost effective agriculture system based on iot using sustainable energy. *6th International Conference on Trends in Electronics and Informatics (ICOEI)*, <https://doi.org/10.1109/ICOEI53556.2022.9776726>
- Villordon, A., Clark, C. A., Ferrin, D. L., & LaBonte, D. (2009). Using growing degree days, agrometeorological variables, linear regression, and data mining methods to help improve prediction of sweetpotato harvest date in louisiana. *Horttechnology*. <https://doi.org/10.21273/horttech.19.1.133>
- Yang, R., Yang, H., Ji, F., & He, D. (2024). Enhancing the photon yield of hydroponic lettuce through stage-wise optimization of the daily light integral in an led plant factory. *Agronomy*. <https://doi.org/10.3390/agronomy14122949>
- Yates, L. A., Aandahl, Z., Richards, S. A., & Brook, B. W. (2023). Cross validation for model selection: A review with examples from ecology. *Ecological Monographs*, 93(1), e1557. <https://doi.org/10.1002/ecm.1557>
- Zavafer, A., Mancilla, C., Jolley, G., & Murakami, K. (2023). On the concepts and correct use of radiometric quantities for assessing the light environment and their application to plant research. *Biophysical Reviews*, 15(3), 385–400. <https://doi.org/10.1007/s12551-023-01051-y>
- Zhang, C. (2018, April 18). Greenhouse intelligent control system based on microcontroller. *AIP Conf. Proc.* [Konferans Sunumu Özet]. 1955(1): 040033. <https://doi.org/10.1063/1.5033697>
- Zhang, C., Liu, Z., Wang, Y., & Ma, L. (2023). Design and analysis of IoT-based soil information monitoring system for intelligent agricultural greenhouses. *Journal of Artificial Intelligence Practice*, 6, 63–69.
- Zhang, M., Cui, J., Ju, J., Hu, Y., Liu, X., He, R., Song, J., Huang, Y., & Liu, H. (2025). The impact of daily light integral from artificial lighting on tomato seedling cultivation in plant factory. *Agronomy*, 15(1), 70. <https://doi.org/10.3390/agronomy15010070>