



**NESNELERİN İNTERNETİ (IOT) TABANLI DERİN
ÖĞRENME İLE TARIMDA SÜRDÜRÜLEBİLİR
SU YÖNETİMİ SİSTEMİNİN GELİŞTİRİLMESİ**

Ahmet ÖZMEN

**Doktora Tezi
Elektrik Elektronik Mühendisliği Ana Bilim Dalı
Prof. Dr. Mehmet ERTUĞRUL**

2025

(Her hakkı saklıdır)

T.C.
ATATÜRK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI

**NESNELERİN İNTERNETİ (IOT) TABANLI DERİN ÖĞRENME İLE TARIMDA
SÜRDÜRÜLEBİLİR SU YÖNETİMİ SİSTEMİNİN GELİŞTİRİLMESİ**

(Development of Sustainable Water Management System in Agriculture with Internet of
Things (IoT) Based Deep Learning)

DOKTORA TEZİ

Ahmet ÖZMEN

Danışman: Prof. Dr. Mehmet ERTUĞRUL

Erzurum

Temmuz, 2025

KABUL VE ONAY TUTANAĞI

Ahmet ÖZMEN tarafından hazırlanan “Nesnelerin İnterneti (IoT) Tabanlı Derin Öğrenme ile Tarımda Sürdürülebilir Su Yönetimi Sisteminin Geliştirilmesi” başlıklı çalışması 23 / 07 / 2025 tarihinde yapılan tez savunma sınavı sonucunda başarılı bulunarak jürimiz tarafından Elektrik Elektronik Mühendisliği Ana Bilim Dalı, Elektronik Bilim Dalında doktora tezi olarak kabul edilmiştir.

Jüri Başkanı:	Prof. Dr. Nur Hüseyin KAPLAN <i>Erzurum Teknik Üniversitesi</i>	Aslı ıslak imzalıdır
Danışman:	Prof. Dr. Mehmet ERTUĞRUL <i>Karadeniz Teknik Üniversitesi</i>	Aslı ıslak imzalıdır
Jüri Üyesi:	Prof. Dr. Yunus BABACAN <i>Erzincan Binali Yıldırım Üniversitesi</i>	Aslı ıslak imzalıdır
Jüri Üyesi:	Doç. Dr. Emin Argun ORAL <i>Atatürk Üniversitesi</i>	Aslı ıslak imzalıdır
Jüri Üyesi:	Dr. Öğr. Üyesi Faruk Baturalp GÜNAY <i>Atatürk Üniversitesi</i>	Aslı ıslak imzalıdır Enstitü Yönetim Kurulunun .../.../.... tarih ve sayılı kararı.

Bu tezin Atatürk Üniversitesi Lisansüstü Eğitim ve Öğretim Yönetmeliği'nin ilgili maddelerinde belirtilen şartları yerine getirdiğini onaylarım.

Prof. Dr. Alper NUHOĞLU
Enstitü Müdürü

Bu çalışma BAP projeleri kapsamında desteklenmiştir.
Proje No: MYO.23.002

Not: Bu tezde kullanılan özgün ve başka kaynaklardan yapılan bildiriş, çizelge, şekil ve fotoğrafların kaynak olarak kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

ETİK BİLDİRİM VE İNTİHAL BEYAN FORMU

Doktora Tezi olarak *Prof. Dr. Mehmet ERTUĞRUL* danışmanlığında sunulan “Nesnelerin İnterneti (IoT) Tabanlı Derin Öğrenme ile Tarımda Sürdürülebilir Su Yönetimi Sisteminin Geliştirilmesi” başlıklı çalışmanın tarafımızdan bilimsel etik ilkelere uyularak yazıldığını, yararlanılan eserlerin kaynakçada gösterildiğini, Fen Bilimleri Enstitüsü tarafından belirlenmiş olan Turnitin Programı benzerlik oranlarının aşılmadığını ve aşağıdaki oranlarda olduğunu beyan ederiz.

Tez Bölümleri	Tezin Benzerlik Oranı (%)	Maksimum Oran (%)
Giriş	1	30
Kuramsal Temeller	1	30
Materyal ve Yöntem	4	35
Araştırma Bulguları ve Tartışma	0	20
Sonuçlar ve Öneriler	0	20
Tezin Geneli	4	25

Not: Yedi kelimeye kadar benzerlikler ile Başlık, Kaynakça, İçindekiler, Teşekkür, Dizin ve Ekler kısımları tarama dışı bırakılabilir. Yukarıdaki azami benzerlik oranları yanında tek bir kaynaktan olan benzerlik oranlarının %5'den büyük olmaması gerekir.

Beyan edilen bilgilerin doğru olduğunu, aksi halde doğacak hukuki sorumlulukları kabul ve beyan ederiz.

Tez Yazarı (Öğrenci)	Tez Danışmanı
Ahmet ÖZMEN	Prof. Dr. Mehmet ERTUĞRUL
12.7.2025	12.7.2025
İmza: Aslı ıslak imzalıdır	İmza: Aslı ıslak imzalıdır

* Tez ile ilgili YÖKTEZ’de yayınlamasına ilişkin bir engelleme var ise aşağıdaki alanı doldurunuz.

☐ Tezle ilgili patent başvurusu yapılması / patent alma sürecinin devam etmesi sebebiyle Enstitü Yönetim Kurulunun .../.../.... tarih ve sayılı kararı ile teze erişim 2 (iki) yıl süreyle engellenmiştir.

☐ Enstitü Yönetim Kurulunun .../.../.... tarih ve sayılı kararı ile teze erişim 6 (altı) ay süreyle engellenmiştir.

TEŞEKKÜR

Lisans, yükseköğrenim ve akademik çalışmalarım boyunca bilgilerini, tecrübelerini esirgemeyen değerli hocam Prof. Dr. Mehmet ERTUĞRUL'a, tez çalışmam süresince bilgi ve deneyimleriyle katkı sunan, yapıcı geri bildirimleri ile çalışmamın gelişimine katkı sağlayan kıymetli hocalarım Prof. Dr. Erdal ELKOCA, Doç. Dr. Emin Argun ORAL, Dr. Öğr. Üyesi Faruk Baturalp GÜNAY ve Dr. Öğr. Üyesi Yaşar Özkan YEŞİLBAĞ'a teşekkür ederim.

Tanıdığım günden itibaren hayatımı her gün daha da güzelleştiren ve desteğiyle bu süreçte bana güç veren eşim Kerime Meryem ÖZMEN'e teşekkür ederim.

Bu tez çalışması, TÜBİTAK Bilim İnsanı Destek Programları Başkanlığı (BİDEB) 2211-C Yurt İçi Öncelikli Alanlar Doktora Burs Programı kapsamında desteklenmiştir. Desteğinden dolayı TÜBİTAK'a teşekkür ederim.

Ahmet ÖZMEN

ÖZET

DOKTORA TEZİ

NESNELERİN İNTERNETİ (IOT) TABANLI DERİN ÖĞRENME İLE TARIMDA SÜRDÜRÜLEBİLİR SU YÖNETİMİ SİSTEMİNİN GELİŞTİRİLMESİ

Ahmet ÖZMEN

Danışman: Prof. Dr. Mehmet ERTUĞRUL

Amaç: Bu çalışma, tarımsal sulama yönetiminde geleneksel sensör tabanlı yöntemlere alternatif olarak, görüntü işleme ve yapay zekâ entegrasyonu ile geliştirilen düşük maliyetli bir modelin tasarlanması ve doğruluk düzeyinin test edilmesini amaçlamaktadır.

Yöntem: Çalışma kapsamında, bir sezon boyunca fasulye bitkilerinden IoT tabanlı düşük çözünürlüklü kameralarla toplanan görseller, YOLOv12 algoritması ile segmentasyon ve poz tahmini işlemine tabi tutulmuştur. Görsellerden elde edilen yaprak yüzey alanı, meyve yüzey alanı, toplam bitki alanı ve yaprak eğilme açısı gibi morfolojik değişkenler, yapay sinir ağı (YSA) modeline aktarılmış ve bu model aracılığıyla bitki katsayısı (Kc) ve bitki su tüketimi (ETc) tahmin edilmiştir. Modelin doğruluğu, meteorolojik verilerle geliştirilen geleneksel tahmin yöntemleri ve literatürdeki bulgularla karşılaştırılarak değerlendirilmiştir.

Bulgular: YSA modeli, Kc tahmininde $R^2 = 0,95$ ve ETc tahmininde ise $R^2 = 0,97$ doğruluk oranına ulaşmıştır. Yaprak eğilme açısı değişkeninin modele dâhil edilmesi, özellikle ETc tahmin doğruluğunu anlamlı düzeyde artırmıştır. Düşük çözünürlüklü görsellerle dahi başarılı segmentasyon ve poz tahmini yapılabildiği, bu sayede düşük maliyetli IoT entegrasyonunun mümkün olduğu gösterilmiştir.

Sonuç: Görüntü işleme ile elde edilen yaprak eğilme açısı gibi morfolojik veriler, YSA modelinin Kc ve ETc tahmin doğruluğunu önemli ölçüde artırmıştır. Bu yaklaşım, sensörsüz ve IoT temelli sistemlerle sulama yönetiminde etkin bir alternatif sunarak sürdürülebilir tarıma katkı sağlamaktadır.

Anahtar Kelimeler: görüntü işleme, yapay sinir ağı, IoT, segmentasyon, poz tahmini.

Temmuz 2025, 99 sayfa

ABSTRACT

PH. D. DISSERTATION

DEVELOPMENT OF SUSTAINABLE WATER MANAGEMENT SYSTEM IN AGRICULTURE WITH INTERNET OF THINGS (IOT) BASED DEEP LEARNING

Ahmet ÖZMEN

Supervisor: Prof. Dr. Mehmet ERTUĞRUL

Purpose: This study aims to design and test the accuracy of a low-cost model developed with the integration of image processing and artificial intelligence as an alternative to traditional sensor-based methods in agricultural irrigation management.

Method: Within the scope of the study, images collected from bean plants with IoT-based low-resolution cameras during a season were subjected to segmentation and pose estimation with the YOLOv12 algorithm. Morphological variables such as leaf surface area, fruit surface area, total plant area and leaf bending angle obtained from the images were transferred to an artificial neural network (ANN) model and plant coefficient (Kc) and plant water consumption (ETc) were estimated through this model. The accuracy of the model was evaluated by comparing with the traditional prediction methods developed with meteorological data and the findings in the literature.

Findings: The ANN model reached $R^2 = 0,95$ and $R^2 = 0,97$ for Kc and ETc prediction, respectively. The inclusion of the leaf tilt angle variable in the model significantly increased the prediction accuracy, especially for ETc. It has been shown that successful segmentation and pose estimation can be performed even with low resolution images, thus enabling low-cost IoT integration.

Results: Morphological data such as leaf bending angle obtained by image processing significantly improved the Kc and ETc prediction accuracy of the ANN model. This approach contributes to sustainable agriculture by providing an effective alternative in irrigation management with sensorless and IoT-based systems.

Keywords: image processing, artificial neural network, IoT, segmentation, pose estimation.

January 2025, 99 pages

İÇİNDEKİLER

KABUL VE ONAY TUTANAĞI.....	i
ETİK BİLDİRİM VE İNTİHAL BEYAN FORMU	ii
TEŞEKKÜR	iii
ÖZET	iv
ABSTRACT	v
İÇİNDEKİLER.....	vi
TABLolar DİZİNİ.....	viii
ŞEKİLLER DİZİNİ	ix
KISALTMALAR VE SİMGELER DİZİNİ	xi
GİRİŞ.....	1
Tezin Amacı.....	6
KURAMSAL TEMELLER.....	7
Tarımda IoT Uygulamaları	7
Tarımda YOLO Algoritmalarının Kullanımı	10
Bitkilerde Su İhtiyacının Tespiti	14
Kc Tahmininde Kullanılan Yöntemler ve Yapılan Çalışmalar	18
Mahsul Su Stresi Tahmini için Yapılan Çalışmalar	22
MATERYAL VE YÖNTEM	29
IoT Sisteminin Kurulması ve Veri Setinin Toplanması	30
IoT Ortamları için Veri Tabanı Teknolojileri	40
Görüntü İşleme.....	41
YOLOv12 mimarisi	43
Omurga (backbone) modülü	44
Boyun (Neck) modülü.....	44
Kafa (Head) modülü.....	45
YOLO Tabanlı Segmentasyon ve Poz Eğitimi	47
Öznitelikleri Kullanarak Bitki Morfolojik Özelliklerinin Çıkarılması	48
Tahmin Modeli ve Performans Değerlendirmesi	52
ARAŞTIRMA BULGULARI VE TARTIŞMA.....	55
IoT Veri Tabanı Analiz Sonuçları.....	55
Segmentasyon Eğitim Sonuçları	58
Poz Eğitim Sonuçları	62
Öznitelikleri Kullanarak Bitki Morfolojik Özelliklerinin Çıktıları.....	64

Kc Tahmin Sonuçları	66
ETc Tahmin Sonuçları	68
SONUÇLAR VE ÖNERİLER	73
KAYNAKÇA	75
ÖZGEÇMİŞ.....	84



TABLÖLAR DİZİNİ

Tablo 1. Toprak Analizi Sonuçları.....	33
Tablo 2. Parsel Başına Toplam Sulama Suyu.....	36
Tablo 3. Elektronik Sistem Bileşenleri	39
Tablo 4. ESP32 Teknik Özellikleri.....	39
Tablo 5. YOLO Modellerinin Ayırıcı Özellikleri.....	43
Tablo 6. Dikkat Mekanizmalarının Karşılaştırılması	45
Tablo 7. Etiketlenen Nesne Sayıları.....	48
Tablo 8. İşlemlere Göre Gecikme Süreleri	58
Tablo 9. YOLOv12x-Seg Modelinin Sınırlayıcı Kutu Performans Sonuçları.....	61
Tablo 10. YOLOv12x-Seg Modelinin Maske İçin Performans Sonuçları	62
Tablo 11. YOLOv12x-Pose Modelinin Maske İçin Performans Sonuçları.....	64
Tablo 12. Kc Tahmin Sonuçları.....	67
Tablo 13. ETc Tahmin Sonuçları.....	72
Tablo 14. Literatürdeki Benzer Çalışmaların Kıyaslaması.....	72

ŞEKİLLER DİZİNİ

Şekil 1. Obje algılama yöntemlerine göre kullanılan algoritmalar	4
Şekil 2. Roy ve arkadaşlarının (2022), meyve boyutlarının bitki büyüme aşamalarına göre tespit görselleri, bitki büyüme aşamalarını 1 den 4'e kadar sıralamışlardır.....	11
Şekil 3. Bitki örtüsü endekslerinden NDVI (bantlar 6, 3 ve 4), TCARI/OSAVI (bantlar 1, 4, 5 ve 6), PRI (bantlar 1 ve 2) ve PRInorm (bantlar 1, 2, 4, 5 ve 6) ile termal endekslerden CWSI (bant 7) hesaplamalarında kullanılan yaprak spektral yansıması ve termal bandı içeren elektromanyetik spektrum bileşenleri gösterilmektedir.....	24
Şekil 4. Rossi vd (2022) çalışmasında kullandığı deney sisteminin şematik gösterimi.....	26
Şekil 5. Briglia vd (2020) yaprak açısını belirlemek için kullanılan protokolün şematik diyagramı.....	27
Şekil 6. Önerilen yöntemin akış diyagramı	30
Şekil 7. Saksı dikimi ile ön çalışma sistemi	31
Şekil 8. a) Parsel detayları ve kamera yerleşim düzeni b) açık tarla planı.....	32
Şekil 9. 100%, 75%, 50% ve 25% ETc oranları ile sulanan bitki görselleri ve sarı kesikli çizgiler nemli bölge sınırlarının göstermektedir.	33
Şekil 10. SUET programının kullanımı.....	34
Şekil 11. SUET sulama programı raporu	34
Şekil 12. Damlamam sulama sistemi	37
Şekil 13. Elektronik kart devre şeması.....	37
Şekil 14. Elektronik kart sisteminin PCB üzerine uygulanması	38
Şekil 15. Sulama sisteminde kullanılan IoT tabanlı görüntü toplama bileşeni	40
Şekil 16. YOLOv12 'nin diğer popüler yöntemlerle gecikme-doğruluk kıyaslaması	42
Şekil 17. Dikkat mekanizmaları. a) çapraz dikkat, b) pencere dikkat, c) eksenel dikkat, d) alan dikkat mekanizması	45
Şekil 18. YOLOv12 mimarisi	46
Şekil 19. Bitki su ihtiyacı tahmininde takip edilen işlem adımları	49
Şekil 20. Şematik temsili yaprak görselinde referans noktaları a) $\hat{A}$ açının 180 dereceye yakın olması, su stresinin olmadığını gösterir. b) $\hat{A}$ açının 180 dereceden düşük olması, su stresinin varlığını gösterir.....	50
Şekil 21. Gerçek yaprak görselinde poz noktaları a) $\hat{A}$ açısına göre su stresinin olmadığı yaprak görseli, b) $\hat{A}$ açısına göre su stresinin olduğu yaprak görseli.	51
Şekil 22. Su stresi varlığının tespitinde kullanılan referans nokta işaretlerine göre yaprakların farklı konumları	52

Şekil 23. Kaydetme işlemlerinde oluşan gecikmeler	56
Şekil 24. Arama işlemlerinde oluşan gecikmeler	57
Şekil 25. YOLOv12x-Seg modelinin eğitim metrikleri	59
Şekil 26. YOLOv12x-Seg modelinin sınırlayıcı kutu için performans sonuçları, a) keskinlik - güven grafiği, b) duyarlılık - güven grafiği, c) F1 - güven grafiği, d) keskinlik - duyarlılık grafiği.....	60
Şekil 27. YOLOv12x-Seg modelinin maske için performans sonuçları, a) keskinlik - güven grafiği, b) duyarlılık - güven grafiği, c) F1- güven grafiği, d) keskinlik - duyarlılık grafiği.	61
Şekil 28. YOLOv12x-Pose modelinin eğitim metrikleri	62
Şekil 29. YOLOv12x-Pose modelinin performans sonuçları, a) keskinlik - güven grafiği, b) duyarlılık - güven grafiği, c) F1 - güven grafiği, d) keskinlik - duyarlılık grafiği.	63
Şekil 30. a) Segmentasyon tahminini kullanan örnek görüntü, b) yaprak ve meyve segmentasyonu gösterimi	64
Şekil 31. Yaprak ve bitki segmentasyon çıktısı	65
Şekil 32. Poz tahmininde kullanılan referans noktaların çıktıları	65
Şekil 33. Poz tahmini kullanılarak elde edilen $\hat{A}$ açısının ve yaprak yönlerini gösteren çıktısı	66
Şekil 34. Kc ile bitki görselleri arasındaki ilişki	68
Şekil 35. Yaprak eğilme açıları gösterimi, su stresinin başladığını gösteren görsel	69
Şekil 36. Eksene düz olan yaprağın bulunduğu görsel.....	70
Şekil 37. +Y yönünde 170 dereceden düşük açının olduğu görsel	70
Şekil 38. Su stresinin arttığını gösteren görsel.	71
Şekil 39. Su stresinin arttığını gösteren görsel.	71

KISALTMALAR VE SİMGELER DİZİNİ

AI	: Artificial Intelligence (Yapay Zekâ)
ANN	: Artificial Neural Network (Yapay Sinir Ağı)
A2	: Area Attention Module (Alan Dikkat Modülü)
CWR	: Crop Water Requirement (Bitki Su İhtiyacı)
CWSI	: Crop Water Stress Index (Bitki Su Stresi İndeksi)
CNN	: Convolutional Neural Network (Evrilimli Sinir Ağı)
Ea	: Su Uygulama Randımanı
Ec	: Su İletim Randımanı
ETo	: Referans Bitki Su Tüketimi (mm)
ETc	: Bitki Su Tüketimi (mm)
F1	: F1 Skoru (Doğruluk ve Duyarlılığın Harmonik Ortalaması)
FP	: False Positive (Yanlış Pozitif)
FN	: False Negative (Yanlış Negatif)
GAN	: Generative Adversarial Network (Üretici Çekişmeli Ağ)
IoT	: Internet of Things (Nesnelerin İnterneti)
IoU	: Intersection over Union (Kesişim/Birleşim Oranı)
İHA	: İnsansız Hava Aracı
Kc	: Bitki Katsayısı
mAP	: Mean Average Precision (Ortalama Hassasiyet)
MAE	: Mean Absolute Error (Ortalama Mutlak Hata)
MAPE	: Mean Absolute Percentage Error (Ortalama Mutlak Yüzde Hata)
MSE	: Mean Squared Error (Ortalama Kare Hatası)
NDVI	: Normalized Difference Vegetation Index (Normalize Edilmiş Bitki Örtüsü İndeksi)
OTA	: Over-the-Air (Kablosuz Yazılım Güncelleme)
PCB	: Printed Circuit Board (Baskı Devre Kartı)
Pe	: Etkili Yağış (mm)
Ps	: Bitki tarafından gölgelenen alan yüzdesi
PWM	: Pulse Width Modulation (Darbe Genişlik Modülasyonu)
R ²	: Determinasyon Katsayısı
R-CNN	: Region-based Convolutional Neural Network (Bölge Tabanlı Evrilimli Sinir Ağı)
R-ELAN	: Residual Efficient Layer Aggregation Network (Artık Katman Birleştirme Ağı)

RMSE	: Root Mean Squared Error (Kök Ortalama Kare Hatası)
RTC	: Real-Time Clock (Gerçek Zaman Saati)
SUET	: Sulama Yönetimi ve Bitki Su Tüketimi Hesaplama Sistemi
TP	: True Positive (Doğru Pozitif)
YOLO	: You Only Look Once (Gerçek Zamanlı Nesne Algılama Modeli)



GİRİŞ

Bilgisayarlı görü, 1960'larda basit piksel analizi ve kenar tespiti algoritmalarıyla başlayan yolculuğunu, günümüzde derin öğrenme devrimiyle birlikte otonom sistemlerden tıbbi teşhise kadar kritik alanlarda kilit rol oynayan bir disipline dönüşmüştür. Erken dönemdeki Moravec paradoksunun sınırladığı "makine görme" yetisi, evrimsel sinir ağları (CNN), üretici çekişmeli ağlar (GAN) ve transfer mimarileri gibi yapılarla çözülmüş; 2012 yılında AlexNet'in ImageNet başarısı, bu alanda dönüm noktası olmuştur. Bugün bilgisayarlı görü, nesne tanıma, görüntü sınıflandırma, anlamsal bölütleme, nesne takibi, görüntü üretimi ve anomali tespiti gibi çeşitli görevlerde uzmanlaşmış modellere sahiptir. Bilgisayarlı görü, tıptan endüstriyel otomasyona, savunmadan tarıma kadar geniş bir uygulama alanına yayılmış, özellikle tarımsal teknolojilerde hastalık tanılama, kalite kontrol ve verim tahmini gibi alanlarda aktif olarak kullanılmaya başlanmıştır. Bilgisayarlı görü tabanlı tarım teknolojileri, geleneksel yöntemlerin sınırlarını aşarak veri odaklı karar destek sistemlerinin temel bileşenlerinden biri haline gelmiştir. Bu teknolojinin güçlü bir bileşeni olan derin öğrenme, bitki morfolojisi gibi görsel verilerden anlamlı çıkarımlar yaparak, bitki sağlığı ve su ihtiyacı gibi parametrelerin tahminine önemli katkılar sağlamaktadır.

Bugün geline nokta, bilgisayarlı görü yalnızca nesne tanıma, görüntü sınıflandırma, anlamsal bölütleme, nesne takibi, görüntü üretimi ve anomali tespiti gibi uzmanlaşmış görevleri yerine getirmekle kalmayıp, aynı zamanda çok katmanlı bilişsel süreçlerin otomasyonu için temel bir araç olarak kullanılmaktadır. Bu bağlamda, bilgisayarlı görünün gelişimi; hesaplama gücündeki artış, algoritmik yenilikler ve çok disiplinli uygulama alanları arasındaki dinamik etkileşimle şekillenmiş; başlangıçta yeni gelişmekte olan bir alan iken günümüzde çağdaş teknolojik altyapının temel taşlarından biri haline gelmiştir. Bu teknolojik dönüşümden en çok etkilenen alanlardan biri de tarımdır. Tarım sektörünün, artan dünya nüfusu, iklim değişikliği ve su kaynaklarının azalması gibi küresel sorunlar karşısında daha verimli, sürdürülebilir ve akıllı çözümlere ihtiyaç duyduğu günümüzde; bilgisayarlı görü sistemleri, tarımsal üretim süreçlerinin izlenmesi ve optimize edilmesi için güçlü araçlar sunmaktadır. Özellikle bitki gelişim evrelerinin takibi, hastalık tespiti, hasat zamanının belirlenmesi ve su ihtiyacının doğru hesaplanması gibi süreçlerde bilgisayarlı görü destekli sistemler, geleneksel yöntemlere kıyasla daha hızlı, daha hassas ve ölçeklenebilir çözümler üretmektedir.

Bitki su döngüsünün temel bir bileşeni olan evapotranspirasyon (ETc), su döngüsünün temelinde yar aldığından dolayı sulama verimliliği ve su kaynaklarının sürdürülebilir yönetimi açısından kritik bir öneme sahiptir (Han et al., 2021). Bitkilerin terleme yoluyla su kaybetmesi ve toprağın yüzeyinden suyun buharlaşması sonucu ortaya çıkan ETc, sulama ihtiyacının doğru belirlenmesinde önemli bir rol oynamaktadır (Qiu et al., 2019). Özellikle su kıtlığı yaşanan bölgelerde, ETc'nin doğru tahmin edilmesi gereksiz su kullanımını önleyerek hem su tasarrufu sağlar hem de bitkilerin kuraklık stresine girmesini engeller (M. Liu et al., 2023). ETc'nin etkin yönetimi, su arzı ve talebinin dengelenmesine yardımcı olarak aşırı yeraltı suyu tüketimini azaltır ve tarımsal üretkenliği artırırken suyun daha verimli kullanılmasını sağlar (B. Zhang et al., 2013). İklim değişikliği ve artan küresel gıda talebi göz önüne alındığında, ETc'nin doğru tahmini sürdürülebilir tarım için hayati bir öneme sahiptir (Keabetswe et al., 2024).

ETc tahmini için bugüne kadar çeşitli yöntemler geliştirilmiştir. İlk yöntemlerde, meteorolojik verilere dayanan ampirik ve yarı ampirik denklemler önerilmiştir. Bu yöntemler arasında Penman-Monteith, Priestley-Taylor ve Blaney-Criddle en yaygın kullanılanlar arasında yer almaktadır (Kashyap & Panda, 2001; Keabetswe et al., 2024; Qiu et al., 2019). Özellikle Penman-Monteith yöntemi, referans bitki evapotranspirasyonunun tahmininde sıklıkla başvurulmuş ve diğer yöntemlerin doğruluğunu değerlendirmede standart kabul edilen bir yöntem haline gelmiştir (Keabetswe et al., 2024). Ancak, bu yöntemin pratikte uygulanmasındaki en büyük zorluk; hava sıcaklığı, rüzgar hızı, nem ve güneş radyasyonu gibi birçok sensör verisine ihtiyaç duymasındır. Bu durum, ampirik denklemlerin yerine alternatif tahmin yöntemlerine duyulan ihtiyacı artırmıştır. Bu ihtiyacı karşılamak amacıyla yapay zeka (AI) tabanlı yöntemler geliştirilmiş ve bu yöntemlerle ETc değerinin tahmini başarıyla gerçekleştirilmiştir (Tunalı et al., 2023).

Güncel çalışmalarda, zaman serisi analizleri, yapay sinir ağları ve çeşitli makine öğrenmesi yöntemleri ETc tahmininde yaygın olarak kullanılmaktadır (Saggi & Jain, 2022). Ancak, bu yöntemlerin büyük çoğunluğu hâlâ meteorolojik verilere veya çeşitli sensör verilerine bağımlıdır. Özellikle su stresi (Ihuoma & Madramootoo, 2017; N. Paul et al., 2025), verim tahmini (Rahim et al., 2022) ve Su Stresi İndeksi (CWSI) (Peeters et al., 2024) gibi alanlarda başarılı sonuçlar veren uzaktan algılama sistemleri, sensör bağımlılığını azaltmak adına önemli bir alternatif olarak öne çıkmaktadır (Narendra S. Chandel et al., 2022; Narendra Singh Chandel et al., 2021a, 2024). Bu sistemler aracılığıyla yürütülen son çalışmalarda, RGB görüntüler kullanılarak su stresinin tespitinde %98,4 doğruluk oranına ulaşılmıştır (Narendra S. Chandel et al., 2022). Digital RGB kamera ile yapılan farklı bir

çalışmada ise buğday ve mısır bitkilerinde su stresi tahmininde sırasıyla %92,9 ve %97,9 doğruluk elde edilmiştir (Narendra Singh Chandel et al., 2024).

Son dönemlerde bitki su stresi tespitine yönelik yöntemlerde önemli ilerlemeler kaydedilmiştir. Bu gelişmeler, özellikle uzaktan algılama tekniklerinin kullanımının yanı sıra (Zeyliger & Ermolaeva, 2021), farklı fizyolojik parametrelerin değerlendirilmesini de kapsamaktadır (Gou et al., 2024; Morchid et al., 2024). Renk bilgisine dayalı olarak yapay zeka yöntemleriyle bitkilerin stres durumunu sınıflandırmaya yönelik çalışmalar da bu alandaki çeşitliliği artırmaktadır (Narendra S. Chandel et al., 2022; Narendra Singh Chandel et al., 2021b, 2024; Younes et al., 2024). Bununla birlikte, yaprak eğilme açısının su stresi belirleme potansiyeline odaklanan çalışmalar oldukça sınırlıdır. Bu nedenle, yaprak eğilme açısını esas alan su stresi tespiti için yeni metodolojilere ihtiyaç duyulmaktadır. Briglia vd (2020), hem 3D görüntüleme hem de gonyometre kullanarak gerçekleştirdikleri çalışmada, yaprak açısının su stresi ile doğrusal bir ilişki gösterdiğini ortaya koymuştur. Araştırma bulguları, stres altındaki bitkilerde yaprak açısının değiştiğini ve bu değişim su stresinin bir göstergesi olduğunu ortaya koymuştur (Briglia et al., 2020).


Günümüzde Kc (mahsul katsayısı) değerinin tahmini genellikle bitki indeksleri ve uzaktan algılama tekniklerine dayanmaktadır. Kamble vd (2013), çalışmalarında uydu reflektans verilerinden elde edilen Normalized Difference Vegetation Index (NDVI) gibi uzaktan algılama temelli göstergelerle Kc değerlerinin dolaylı olarak tahmin edilmesine odaklanmıştır (Kamble et al., 2013). Pôças vd (2015) ise, uzaktan algılanan bitki indeksleri ile toprak su dengesi verilerini kullanarak mahsul katsayılarını tahmin etmeye yönelik bir yaklaşım geliştirmiştir (Pôças et al., 2015). Gautam vd (2021) , çok spektralli kameralar ve insansız hava araçları (İHA) kullanarak üzüm bağlarının kanopi yapısına dayalı Kc tahmininde bulunmuş; bu çalışmaları, İHA teknolojisi ile elde edilen görüntülerin işlenerek bitki sağlığı ve su kullanımının modellenmesinde nasıl kullanılabileceğini ortaya koymuştur (Gautam et al., 2021).

Benzer şekilde, Marcial-Pablo vd (2021), mısır bitkisi için çoklu spektral görüntülerden türetilen bitki indeksleri ve bitki örtüsü oranlarını kullanarak Kc tahmini yapmıştır. Çalışmada, deneysel mısır parsellerinden elde edilen çoklu görüntüler, OBIA (Nesne Tabanlı Görüntü Analizi) yaklaşımıyla pikselleri bitki örtüsü, gölge ve toprak olmak üzere üç sınıfa ayıracak şekilde sınıflandırılmıştır (Marcial-Pablo et al., 2021). Öte yandan Malachy vd (2022), İHA görüntüleri üzerinde Yapıdan Hareketle (SfM) tekniklerini kullanarak mahsul yükseklik modelleri (CHM) oluşturmuş ve bu modeller üzerinden Kc tahmini gerçekleştirmiştir. Çalışma, mahsul yüksekliğindeki değişkenliğin tarımsal

uygulamaların yönetiminde nasıl değerlendirilebileceğini ve Kc tahminine katkısını ortaya koymuştur (Malachy et al., 2022).

Bu çalışmalar genel olarak, görüntü işleme yöntemleriyle desteklenen uzaktan algılama sistemlerinin tarımsal uygulamalarda verimli sonuçlar sağlayabileceğini göstermektedir. Ancak, mevcut yaklaşımların çoğunlukla geniş alanlara odaklandığı ve bitki morfolojisindeki ayrıntılı değişkenlikleri yeterince ele almadığı düşünülmektedir. Literatürde, su kullanım verimliliğini artırmak amacıyla bitki bazlı sensörlerin kullanımının önerilmesi (Gautam et al., 2021) ve su stresi katsayısının verime odaklanmak amacıyla bitkinin büyüme aşamasının bir fonksiyonu olarak ağırlıklandırılması gerektiğine ilişkin öneriler (Zeyliger & Ermolaeva, 2021), bitki özelinde yapılacak çalışmalara duyulan gereksinimi açıkça ortaya koymaktadır.

Uzaktan algılama sistemlerinin temel bileşenlerinden biri görüntü işlemedir. Görüntü işleme uygulamalarında, **Şekil 1**'de gösterildiği üzere, iki aşamalı ve tek aşamalı nesne algılama yaklaşımları ön plana çıkmaktadır. İki aşamalı yöntemler arasında yer alan Region-based Convolutional Neural Network (R-CNN), Fast R-CNN, Faster R-CNN ve Mask R-CNN algoritmaları; bitki ve meyve tespiti, verim ve büyüme değerlendirmesi ile otomatik tarım yönetimi gibi uygulama alanlarında önemli gelişmeler sağlamıştır.



Şekil 1. Obje algılama yöntemlerine göre kullanılan algoritmalar

You Only Look Once (YOLO) algoritmaları ise tek aşamalı bir nesne algılama yöntemi olarak gerçek zamanlı performansı sayesinde özellikle tarım alanında yaygın biçimde kullanılmaktadır (Gündüz & Işık, 2023). R-CNN ailesi algoritmaları bölge tabanlı ve iki aşamalı yapılar içerirken, YOLO algoritmaları tek aşamalı yapısıyla daha hızlı çalışmakta ve işlem süresi açısından avantaj sunmaktadır.

Mevcut literatür incelendiğinde, YOLO algoritmasının meyve boyutlarının bitki büyüme evrelerine göre tespiti (Roy & Bhaduri, 2022), domates algılamada (Lawal, 2021), bitki yaprak hastalıklarının belirlenmesinde (Soeb et al., 2023) ve bitki sayımı (A. Paul et al., 2024) gibi birçok tarım uygulamasında başarıyla kullanıldığı görülmektedir. Bu çalışmalar, YOLO algoritmalarının görüntü işlemeye dayalı tarım uygulamalarında yüksek potansiyel sunduğunu ortaya koymaktadır.

Özellikle tespit ve segmentasyon işlemleri açısından değerlendirildiğinde, YOLO algoritmanın tarım alanında yaygın biçimde kullanıldığı görülmektedir (Bai et al., 2023; Ju & Cai, 2023; Lou et al., 2023; Ma & Pang, 2023; A. Paul et al., 2024; Uygun & Ozguven, 2024; Wu et al., 2023; Yue et al., 2023; Zhai et al., 2023). Öte yandan, poz tahmini yöntemi geleneksel olarak insan hareketlerinin analizinde kullanılırken, son yıllarda otomatik sistemlerdeki uygulamaları da yaygınlaşmaya başlamıştır (Jang & Hwang, 2024; Rong et al., 2022).

Tarım uygulayıcıları, uzun yıllar boyunca bitkilerin yaprak, meyve ve tomurcuk gibi bölümlerini görsel olarak inceleyerek su ihtiyacına yönelik çıkarımlarda bulunmuş ve buna göre sulama kararları vermiştir. Günümüzde ise teknolojiye gelişmeler sayesinde, bitkileri sürekli izleyen bir kamera sistemiyle, bitkinin fiziksel özelliklerinden hareketle su ihtiyacını belirleyebilecek algoritmaların kullanılması oldukça muhtemel hale gelmiştir. Nitekim yapılan öncül çalışmalarda, yaprak morfolojisi ile su ihtiyacı arasındaki ilişki ortaya konmuştur (Anjum et al., 2012; C. Zhang et al., 2017). Bu bulgular, yeni teknolojiler aracılığıyla bitki görsellerinden özellik çıkarmanın sürdürülebilir tarım açısından taşıdığı potansiyeli gözler önüne sermektedir.

Ayrıca, Nesnelerin İnterneti (IoT) tabanlı teknolojilerin hızlı gelişimi, özellikle "akıllı tarım" uygulamaları başta olmak üzere birçok sektörde istatistiksel yaklaşımlardan nicel veri temelli yaklaşımlara geçişi hızlandırmıştır (Ayaz et al., 2019). Mevcut çalışmalarda, IoT sistemleri genellikle veri toplama amacıyla kullanılmaktadır (Anagha et al., 2023; Farooq et al., 2022; Nauman et al., 2023; Palomar-Cosín & García-Valls, 2022; Pathmudi et al., 2023; Saranya et al., 2023). Ancak, görüntü işleme temelli uygulamalarda genellikle yüksek çözünürlüklü kameralar tercih edilmiş ve bu sistemlerin IoT ile entegrasyonu henüz yaygın

bir şekilde uygulanamamıştır. 8MP ve 12MP çözünürlüğe sahip kameralarla yürütülen tarımsal araştırmalarda başarılı sonuçlar elde edilmiş olsa da (A. Paul et al., 2024) , bu tür sistemlerin oluşturduğu büyük veri paketleri, IoT sistemleriyle bütünleştirilmesini zorlaştırmaktadır. Bu nedenle, düşük çözünürlüklü kameralarla çalışan, IoT tabanlı ve görsel veri toplayabilen bir sulama sistemine ihtiyaç duyulmaktadır. Ayrıca, yüksek çözünürlüklü kameralar performansı artırmasına rağmen, yüksek maliyetleri nedeniyle tarımda yaygın kullanımları sınırlı kalmaktadır. Buna karşılık, mikroişlemci düzeyinde geliştirilecek düşük maliyetli sistemlerin sürdürülebilir tarım için önemli bir çözüm sunabileceği düşünülmektedir.

Tezin Amacı

Bu tez, bitkilerin su ihtiyacının belirlenmesinde karşılaşılan mevcut sorunlara çözüm getirebilmek amacıyla, bitki morfolojisinin bu süreçte kullanılmasını önermektedir. Önerilen yaklaşım, çok sayıda sensör verisine dayalı sistemler yerine, yalnızca kameradan elde edilen görsellere dayanan bir yapay zekâ destekli sistemin kullanımını esas almaktadır. Bu sistem, kamera aracılığıyla elde edilen görüntüleri işleyerek, Kc ve ETc değerlerinin tahmininde kullanılabilecek çeşitli morfolojik özellikleri çıkarmaktadır. Ayrıca, çıkarılan bu özellikler arasında, bitkinin su stresini belirlemede önemli bir gösterge olan yaprak eğilme açısı da hesaplanmaktadır.

Deneysel çalışma kapsamında, dört farklı su stresi seviyesine maruz bırakılan fasulye bitkilerinin bir sezon boyunca görüntüleri toplanmış ve bu amaçla IoT tabanlı bir izleme sistemi geliştirilmiştir. Toplanan görseller etiketlenmiş, ardından segmentasyon ve poz tahmini işlemleri için YOLO algoritması kullanılarak analiz edilmiştir. Elde edilen morfolojik özellikler yapay sinir ağı (YSA) ile eğitilerek, Kc, ETc ve su stresi tahminleri gerçekleştirilmiştir. Bu tez kapsamında geliştirilen yaklaşım ile, tarımsal su yönetiminde görüntü tabanlı ve sürdürülebilir bir yöntem sunulması; böylece su kullanım verimliliğinin artırılması ve gereksiz su tüketiminin önlenmesi hedeflenmektedir.

KURAMSAL TEMELLER

Tarımda IoT Uygulamaları

IoT, tarımda dönüşüm yaratan yenilikçi bir teknoloji olarak hassas tarım uygulamalarına geçişi mümkün kılmakta; üretkenlik, sürdürülebilirlik ve kaynak etkinliğini artırma potansiyeli sunmaktadır (Ahmed et al., 2018; Ayaz et al., 2019). Bu teknoloji, mahsuller ve çevre koşulları hakkında gerçek zamanlı veri toplayan ve analiz eden birbirine bağlı sensörler ve cihazlar aracılığıyla çalışır. Bu sayede, tarımda bilinçli karar alma süreçleri desteklenirken kaynak kullanımı da optimize edilebilmektedir (Anagha et al., 2023). Irianto ve Rif'an (2024), IoT teknolojilerinin yalnızca mahsul kalitesini iyileştirmekle kalmayıp, aynı zamanda gıda dağıtım sistemlerinin verimliliğini artırarak daha yüksek verimle birlikte fiyatların düşmesine katkı sunduğunu belirtmektedir (Irianto & Rif'an, 2024). Benzer şekilde, Thi (2024), yerel çiftçilik uygulamalarına göre uyarlanmış IoT çözümlerinin mahsul veriminde kayda değer artışlara yol açabileceğini ve bu teknolojilerin özellikle küçük ölçekli çiftçiler arasında yaygınlaştırılması gerektiğini vurgulamaktadır (Thi, 2024).

Tarım sektöründe dijitalleşmenin hız kazanmasıyla birlikte, IoT teknolojileri veriye dayalı karar alma süreçlerinde kritik bir rol oynamaya başlamıştır. Wang ve Yong (2024), Balina Optimizasyon Algoritması gibi meta sezgisel algoritmaların, dinamik tarımsal çevrelerde IoT ağları için verimli yönlendirme stratejileri geliştirmede etkili olduğunu vurgulamıştır (Y. Wang & Yang, 2024). Ayrıca, derin öğrenme ve takviyeli öğrenme tekniklerinin entegrasyonu, tarımsal bağlamlarda IoT sistemlerinin karar destek mekanizmalarını güçlendirerek çiftçilerin daha hızlı ve etkili kararlar almasını sağlamaktadır. Bu veri odaklı sistemler yalnızca çevresel koşullar hakkında bilgi sağlamakla kalmayıp, aynı zamanda sürdürülebilir üretim planlarının oluşturulmasına da katkı sunmaktadır (Isa et al., 2024).

IoT tabanlı sistemlerin tarıma entegrasyonu, çiftçilerin toprak nemi, sıcaklık, zararlı aktivitesi gibi kritik çevresel parametreleri anlık olarak izlemesine imkân tanıyarak akıllı tarım uygulamalarının temelini oluşturmaktadır (Alturif et al., 2024). Bu sistemler, yalnızca düzlük ve erişilebilir arazilerde değil, Liu vd' de (2024) gösterdiği gibi, dağlık ve ulaşımı zor bölgelerdeki üzüm bağları gibi alanlarda da etkin biçimde uygulanabilmektedir. (C. Liu et al., 2024). Bu sayede, tarımsal faaliyetlerde kaynak israfı en aza indirilirken; bulut bilişim ve yapay zekâ destekli veri analizleri aracılığıyla sulama, gübreleme ve ilaçlama gibi tarımsal girdilerin en verimli şekilde kullanılması mümkün hale gelmektedir (Tan et al., 2024).

Özellikle su yönetimi ve sulama sistemlerinde IoT teknolojilerinin kullanımı, geleneksel yöntemlerin neden olduğu verimsizliklerin giderilmesi açısından kritik öneme sahiptir. Balamurali vd (2025), çevre kirleticili konsantrasyonlarına dayalı yağış tahmin sistemleriyle entegre edilmiş IoT tabanlı akıllı sulama uygulamalarının, su kullanımını optimize ederek israfı önlediğini ve mahsullerin ihtiyaç duyduğu nem hassas biçimde sağladığını ortaya koymuştur. Bu sistemlerde güneş enerjisi gibi yenilenebilir kaynakların kullanımı da çevresel sürdürülebilirliği desteklemektedir. IoT ile yenilenebilir enerji entegrasyonu, iklim değişkenliğine uyum sağlayan daha dayanıklı tarım altyapılarının geliştirilmesine katkıda bulunmaktadır.

IoT'nin sağladığı gerçek zamanlı veri analitiği, sulama stratejilerini belirleyen toprak nem, hava koşulları ve bitki sağlığı verilerinin hızlı ve etkili biçimde işlenmesine imkân tanır. Bu bağlamda yapılan araştırmalar, IoT uygulamalarının çiftçilere gelişmiş karar alma yetkinliği kazandırdığını ve değişken çevresel koşullara zamanında müdahale etmelerini sağladığını göstermektedir (Balamurali et al., 2025).

IoT, tarımsal üretimde özellikle sulama ve gübreleme (fertilizasyon) sistemlerinin optimizasyonunda önemli katkılar sağlamaktadır. Geleneksel yöntemlerin neden olduğu su israfı ve besin maddesi kayıplarına karşı, Adamo vd (2025) tarafından önerilen IoT tabanlı mikro hizmet mimarisi, gerçek zamanlı veri analizi ve sensör teknolojileriyle bitkinin anlık ihtiyaçlarına göre su ve besin maddesi uygulamasını otomatikleştirmektedir. Bu sayede su tasarrufu sağlanmakta, gübre kirliliği önlenmekte ve çevresel sürdürülebilirlik desteklenmektedir. Aynı zamanda küçük ölçekli çiftçiler için maliyetleri azaltarak ekonomik sürdürülebilirliğe katkı sunmakta ve iklim değişkenliği gibi risklere karşı tarımsal üretimin direncini artırmaktadır. Bu teknoloji, tarımda veri temelli karar alma süreçlerinin önemini vurgulamakta ve geleceğe yönelik sürdürülebilir çözümler sunmaktadır (Adamo et al., 2025).

Tarımsal uygulamaların teknoloji yoluyla geliştirilmesi bağlamında Paria vd (2025), kişniş yetiştiriciliği için özel olarak tasarlanmış akıllı bir sulama sistemi geliştirmede AI ve IoT teknolojilerinin entegrasyonunu araştırmışlardır. Araştırmalarında, bu teknolojilerin mahsul verimini ve sağlığını artırırken su kullanımını optimize etmedeki kritik rolünü vurgulamışlardır. Toprak nemini ve çevresel koşulları izleyen sensör tabanlı bir sistem uygulayan akıllı sulama çerçevesi, verimli su uygulaması sağlamak için gerçek zamanlı veri girdilerine etkili bir şekilde uyum sağladığı görülmüştür. Bu yaklaşım sadece su kaynaklarını korumakla kalmaz, aynı zamanda çevresel etkiyi en aza indirerek ve sorumlu su yönetimini teşvik ederek sürdürülebilir tarım uygulamalarına katkıda bulunmaktadır. Çalışmada sunulan bulgular, modern tarımda, özellikle su kıtlığı ve artan tarımsal üretkenlik talebinin yarattığı

zorlukların ele alınmasında yapay zeka ve IoT'den yararlanmanın önemini vurgulamaktadır (Paria et al., 2025).

Belkher vd (2025), su kıtlığı sorununu ele almak ve tarımsal verimliliği artırmak amacıyla, yarı kurak koşullarda kışlık buğday yetiştiriciliği için IoT sistemiyle birleştirilmiş eksik sulama stratejilerinin etkinliğini araştırmıştır. Çalışmaları, dikkatli bir şekilde yönetilen sulama uygulamalarıyla birlikte IoT tabanlı bir izleme sisteminin uygulanmasının su kullanım verimliliğini ve mahsul verimini önemli ölçüde artırabileceğini ortaya koymaktadır. Deneme, çeşitli sulama uygulamalarını içermektedir: ETc'nin %100'ünde tam sulama (FI) ve yağmurla beslenen bir uygulamanın (DI3) yanı sıra ETc'nin sırasıyla %75 ve %60'ına ayarlanan iki eksik sulama uygulaması (DI1 ve DI2). Sonuçlar, toplam kuru madde (TDM) ve tane veriminin (GY) uygulanan sulama miktarı ile arttığını ve en yüksek değerlerin FI ve DI1 uygulamaları altında kaydedildiğini göstermiştir. Bu araştırma, verimi en üst düzeye çıkarırken su kaynaklarını optimize etmek için gelişmiş sulama yönetimi tekniklerini IoT teknolojisi ile birleştirme potansiyelinin altını çizmekte ve bu entegre yaklaşımların giderek zorlaşan iklim koşullarında sürdürülebilir tarım uygulamalarına ulaşmada kritik öneme sahip olduğunu ortaya koymaktadır (Belkher et al., 2025).

Hassas tarımın ilerlemesinde, Mamun vd (2025), sürdürülebilirliği teşvik ederken tarımsal verimliliği artırmak için tasarlanmış IoT özellikli güneş enerjili akıllı sulama sistemi üzerine kapsamlı bir çalışma sunmaktadır. Araştırmaları, gerçek zamanlı toprak nemi verilerine dayanarak mahsullere hassas miktarlarda su sağlayabilen otomatik bir sulama çözümü geliştirmek için yenilenebilir enerji kaynaklarını IoT teknolojisi ile entegre etme potansiyelini vurgulamaktadır. Önerilen sistem, çevresel koşulları sürekli olarak izleyen çeşitli sensörler içermektedir ve böylece nem seviyelerine göre sulama programlarında dinamik ayarlamalar yapılmasına olanak tanımaktadır. Bulgular, bu yenilikçi yaklaşımın sadece su kullanımını optimize etmekle kalmayıp aynı zamanda yenilenemeyen enerji kaynaklarına olan bağımlılığı azalttığını ve özellikle elektriğe sınırlı erişimi olan bölgeler için uygun olduğunu göstermektedir. Çalışma, IoT teknolojisi ile birleştirilmiş güneş enerjili sulama sistemlerinin etkinliğini göstererek, bu tür entegrasyonların su yönetimini iyileştirme ve sürdürülebilir tarım uygulamalarını teşvik etme konusundaki dönüştürücü potansiyelinin altını çizmektedir (Al Mamun et al., 2025).

Zhang vd (2025), tarım arazileri için akıllı sulama sistemleriyle ilgili kritik zorlukları ele alırken, uç bilişim ve LoRa iletişim teknolojisinden yararlanan yenilikçi bir IoT tabanlı sulama çözümü önermektedir. Araştırmaları, mevcut sulama uygulamalarındaki yetersiz veri kaynakları, yetersiz entegrasyon, tahrik yürütme ve kontrolde düşük otomasyon ve karar

verme süreçleri için bulut bilişim platformlarına aşırı bağımlılık gibi temel sorunları vurgulamaktadır. Bu engellerin üstesinden gelmek için yazarlar, STM32 mikro denetleyici birimleri (MCU'lar), düşük güçlü LoRa modülleri, 4G modülleri ve yüksek hassasiyetli GPS cihazlarının bir kombinasyonunu kullanarak akıllı sulama için tasarlanmış düğümler ve ağ geçitlerinden oluşan bir sistem geliştirdiler. Bu teknolojileri bütünleştiren sistem, toprak nemi ve meteorolojik koşullara ilişkin gerçek zamanlı verileri toplamaktadır. Bir uç bilişim analizi ve karar modelinin kurulması, tarımsal ortamlarda fikir yürütme ve kontrol süreçlerinin otomasyonunda önemli bir ilerleme anlamına geliştirmişlerdir. Bu çalışmadan elde edilen bulgular, daha dirençli ve verimli tarım uygulamaları oluşturmak için IoT ve uç bilişimin birleştirilmesinin potansiyelinin altını çizmekte ve sonuçta gelişmiş gıda güvenliği ve sürdürülebilir tarım operasyonlarının önünü açmaktadır (Y. Zhang et al., 2025).

Sonuç olarak, tarımda IoT uygulamaları, yalnızca teknolojik bir yenilik değil; aynı zamanda çevresel sürdürülebilirliği, ekonomik verimliliği ve gıda güvenliğini destekleyen çok boyutlu bir dönüşüm aracıdır. Bu sistemler, veriye dayalı karar alma süreçlerini güçlendirerek tarımsal üretimde kalite, verim ve dirençliliği artırmakta; iklim değişikliği gibi küresel sorunlara karşı çözüm geliştirmede stratejik bir rol üstlenmektedir.


Tarımda YOLO Algoritmalarının Kullanımı

Günümüz tarımında, görüntü işleme temelli araştırmalarda YOLO algoritması sıklıkla kullanılacaktır. Literatürdeki çalışmalar incelendiğinde tespit ve segmentasyon işlemi için YOLO algoritmasının yaygın olarak kullanıldığı görülmektedir (Bai et al., 2023; Ju & Cai, 2023; Lou et al., 2023; Ma & Pang, 2023; A. Paul et al., 2024; Uygun & Ozguven, 2024; Wu et al., 2023; Yue et al., 2023; Zhai et al., 2023). Buna karşılık poz tahmini insan hareketleri için yaygın kullanılmasının yanı sıra özellikle otomatik sistemlerde kullanmaya başlandığı görülmüştür (Jang & Hwang, 2024; Rong et al., 2022). Tez çalışmasında literatürdeki bu kullanımlara benzer olarak görüntülerden anlamlı özellikler çıkarmada YOLO algoritmasının segmentasyon ve poz modelleri kullanılacaktır.

Camacho vd (2023) çalışmalarında, hasat tahmini için Mask R-CNN ve YOLOv8 kıyaslamışlardır ve YOLOv8 modeli domatesleri tespit etme, segmentlere ayırma ve sınıflandırma konusunda daha iyi performans gösterdiğini rapor etmişlerdir (Camacho & Morocho-Cayamcela, 2023). Wu vd (2023) çalışmalarında segmentasyon işleminde YOLOv8'in YOLOv7 ve Mask R-CNN göre daha çok parametrede yüksek performansa sahip olduğu sonucuna varmışlardır (Wu et al., 2023). Uygun ve Özgüven (2024) segmentasyon çalışmalarında YOLOv7, YOLOv5l, YOLACT ve Mask R-CNN'e göre YOLOv8'in en iyi performansa sahip olduğunu göstermişlerdir (Uygun & Ozguven, 2024). Yue vd. (2023)

yaptıkları çalışmada ise segmentasyon için YOLOv8'in YOLOv5, YOLOv7 ve Mask R-CNN' dan daha iyi sonuçlara sahip olduğunu belirtmiştir. (Yue et al., 2023). Literatürdeki çalışmalardaki YOLO modellerinin segmentasyon görevlerinde yüksek performans değerlerinde oldukları görülmüştür.

Roy vd (2022), ticari meyve bahçelerinde ürün verimini tahmin etme ve akıllı ilaçlama sistemlerinin etkinliğini artırma açısından kritik öneme sahip olan bitki gelişim evrelerinin gerçek zamanlı tespitine yönelik gelişmiş bir algoritmik yaklaşım sunmuştur. Bu çalışmada, YOLOv4 mimarisinin geliştirilmiş bir versiyonu olan Dense-YOLOv4 önerilmiştir. Modelin omurgasında DenseNet yapısının entegre edilmesiyle özelliklerin aktarımı ve yeniden kullanımı optimize edilmiş, ayrıca hassas yerel bilgilerin korunmasını sağlamak amacıyla modifiye edilmiş PANet eklenmiştir. Görsel çıktısı **Şekil 2**'de görüldüğü üzere mango meyvesinin farklı gelişim evrelerinin, karmaşık bahçe koşullarında ve yaprak örtüsü altında dahi yüksek doğrulukla tespiti hedeflenmiş; model, 44,2 FPS'lik gerçek zamanlı işlem hızıyla %96,20 mAP ve %93,61 F1 skoruna ulaşmıştır. Dense-YOLOv4 mimarisi, geleneksel YOLOv4'e kıyasla doğruluk (%7,94), duyarlılık (%13,10), F1 skoru (%10,47) ve ortalama kesinlik (%4,73) açısından üstün performans sergilemiştir. Bu çalışma, yaprak örtüsü, meyve yoğunluğu, boyut ve renk farklılıklarının model doğruluğu üzerindeki etkilerini başarıyla aşarak, tarımsal gelişim izleme uygulamalarında derin öğrenme tabanlı çözümlerin ne denli güçlü olduğunu göstermektedir (Roy & Bhaduri, 2022).



Şekil 2. Roy ve arkadaşlarının (2022), meyve boyutlarının bitki büyüme aşamalarına göre tespit görselleri, bitki büyüme aşamalarını 1 den 4'e kadar sıralamışlardır.

Camacho ve Morocho-Cayamcela (2023), domateslerin farklı olgunluk evrelerinde tespiti ve segmentasyonu yoluyla hasat tahmini gerçekleştirmek amacıyla geliştirilen derin öğrenme tabanlı yaklaşımları değerlendirmiştir. Çalışmada, Laboro Tomato veri seti kullanılarak hem Mask R-CNN hem de YOLOv8 mimarileri eğitilmiş; elde edilen sonuçlar karşılaştırmalı olarak test edilmiştir. IoU 0.5 değerlendirme metriğine göre Mask R-CNN modeli %67,2 ortalama kesinlik ve %78,9 duyarlılık elde ederken, aynı veri kümesi üzerinde YOLOv8 için kesinlik %92,1 ve duyarlılık %91,4 olarak kaydedilmiştir. Karşılaştırmalı çalışmada ise olgunluk sınıflandırması renk analizine dayalı klasik yöntemlerle yapılmış ve

belirleme katsayısı (R^2) temel alınarak değerlendirilmiştir. YOLOv8 mimarisi, sırasıyla olgun (%0,809), yarı olgun (%0,897) ve yeşil (%0,968) domates sınıflarında yüksek R^2 değerleriyle başarılı sonuçlar üretirken, Mask R-CNN modeli bu kategorilerde sırasıyla %0,819, %0,809 ve %0,893 değerleriyle yeterli performans sergilemiştir. YOLOv8 modeli, hem tespit hem segmentasyon hem de sınıflandırma işlemlerini entegre biçimde gerçekleştirme yeteneğiyle, yalnızca karşılaştırmalı çalışmada kullanılan renk analiz tabanlı yöntemleri değil, aynı zamanda Mask R-CNN modelini de geride bırakmıştır. (Camacho & Morocho-Cayamcela, 2023).

Yue vd (2023), domates üretiminde ciddi verim kayıplarına neden olan enfeksiyon ve çürüme gibi hastalıkların yayılımını önlemek amacıyla, gerçek zamanlı ve yüksek doğrulukta domates segmentasyonu gerçekleştirebilen gelişmiş bir derin öğrenme modeli önermektedir. Bu çalışmada, YOLOv8s-Seg mimarisi geliştirilerek, meyve yüzeyi rengi ve yüzey özelliklerine duyarlı bir şekilde domateslerin segmentasyonu hedeflenmiştir. Modelin özellik birleştirme kabiliyeti, C2f modülünün RepConv bloklarıyla yapılandırılan RepBlock modülü ile değiştirilmesiyle artırılmış; ayrıca iki üst-örnekleme (upsampling) katmanı öncesine ReLU aktivasyon fonksiyonunu kullanan SimConv yerleştirilmiş ve kalan klasik konvolüsyon katmanları SimConv ile değiştirilmiştir. Bu yapısal iyileştirmeler sonucunda model, %88,7 F1 skoru ve %92,2 segment mAP@0,5 değerine ulaşarak; YOLOv8s-Seg, YOLOv5s-Seg, YOLOv7-Seg ve Mask R-CNN gibi önceki modelleri segmentasyon başarımı açısından anlamlı şekilde geride bırakmıştır. Ayrıca, sadece 3,5 ms'lik çıkarım süresiyle gerçek zamanlı örnek segmentasyonu gerçekleştirme yeteneği, bu algoritmayı özellikle sahada uygulanabilir akıllı tarım sistemleri için cazip hâle getirmiştir (Yue et al., 2023).

Soeb vd (2023), çay yaprağı hastalıklarının erken ve doğru şekilde tespiti için yapay zekâ tabanlı bir yaklaşım geliştirerek, manuel teşhis yöntemlerinin neden olduğu zaman kaybı ve verim düşüklüğü sorunlarına çözüm sunmayı amaçlamıştır. Bangladeş'teki dört önde gelen çay bahçesinden toplanan beş farklı yaprak hastalığına ait toplam 4000 dijital görüntü kullanılarak, elle etiketlenmiş ve veri artırımı uygulanmış bir görüntü veri seti oluşturulmuştur. Bu çalışma kapsamında, YOLOv7 algoritması eğitilmiş ve doğruluk, kesinlik, duyarlılık, ortalama hassasiyet (mAP) ve F1 skoru gibi istatistiksel ölçütlerle değerlendirilmiştir. Elde edilen sonuçlar sırasıyla %97,3 doğruluk, %96,7 kesinlik, %96,4 duyarlılık, %98,2 mAP ve 0,965 F1 skoru ile modelin yüksek performansını ortaya koymuştur. YOLOv7, doğal ortam görüntülerinde çay yaprağı hastalıklarının tespiti açısından CNN, Deep CNN, DNN, AX-Retina Net, geliştirilmiş DCNN, YOLOv5 ve çok amaçlı

görüntü segmentasyon modelleri dahil olmak üzere bir çok yöntemi geride bırakmıştır (Soeb et al., 2023).

Uygun vd (2024), sera koşullarında domates bitkilerinin yapraklarında zarara neden olan Tuta Absoluta zararlısının erken tespitine yönelik derin öğrenme tabanlı bir örnek segmentasyon yönteminin etkinliğini araştırmıştır. Çalışmada, 800 adet sağlıklı ve zarar görmüş yaprak görüntüsünden oluşan orijinal bir veri seti oluşturulmuş; bu görüntüler önce sınırlayıcı kutular ile etiketlenmiş, ardından Segment Anything Model (SAM) kullanılarak maske etiketlerine dönüştürülmüştür. Oluşturulan veri seti, farklı YOLOv8 (n/s/m/l/x) mimarilerine ait segmentasyon modelleri ile eğitilmiş ve en yüksek başarıya YOLOv8l-Seg modeli ile ulaşılmıştır. Bu model, $mAP@0,5$ değerinde 0,935, $mAP@0,5-0,95$ değerinde 0,806, keskinlik oranında 0,956 ve duyarlılık oranında 0,859 ile en başarılı sonuçları vermiştir. Ayrıca, farklı giriş boyutlarında yapılan eğitimlerde 640×640 çözünürlükle en iyi performans elde edilirken, 80×80 çözünürlükte model performansı $mAP@0,5$ 'ye kadar düşmüştür. Aynı veri seti üzerinde YOLOv7, YOLOv5l, YOLACT ve Mask R-CNN gibi diğer örnek segmentasyon modelleri ile karşılaştırma yapılmış; en düşük performans Mask R-CNN modelinde ($0,806 mAP@0,5$) gözlenmiştir. Elde edilen bulgular, YOLOv8l-Seg modelinin T. Absoluta zararlısına bağlı yaprak zararlarını hızlı, doğru ve etkili bir şekilde tespit edebildiğini ve sera ortamında zararlı yönetimine yönelik erken uyarı sistemleri için kullanılabilir güçlü bir araç sunduğunu göstermektedir. Bu çalışma, görüntü işleme destekli yapay zekâ uygulamalarının tarımsal zararlı tespitinde nasıl etkin şekilde kullanılabileceğine dair önemli bir örnek teşkil etmektedir (Uygun & Ozguven, 2024).

Sapkota vd (2024), bilgisayarlı görüye dayalı nesne tespiti süreçlerinde büyük hacimli ve etiketli veri setlerine duyulan ihtiyacın getirdiği insan gücü, zaman ve maliyet yükünü azaltmak amacıyla, dil tabanlı görsel üretim sistemlerinin tarımsal veri üretiminde kullanım potansiyelini ortaya koymuştur. Çalışmada, geleneksel görüntü toplama yöntemlerinden farklı olarak, OpenAI'nin gerçekçi görüntüler üretebilen büyük dil modeli DALL·E kullanılarak, elma tespiti amacıyla yapay bir veri seti oluşturulmuş ve bu veri seti YOLOv10 ve YOLOv11 algoritmalarının çeşitli konfigürasyonları ile eğitilmiştir. Üretilen modeller daha sonra gerçek ortamda, Nikon D5100 dijital kamera ve Microsoft Azure Kinect RGB-D kamera ile elde edilen elma bahçesi görüntüleri üzerinde test edilmiştir. YOLOv11 modelleri, özellikle YOLOv11x ($mAP@50 = 0,958$) ve YOLOv11n (keskinlik = 0,916) varyantları ile üstün performans göstermiştir. Gerçek ortam testlerinde YOLOv11s, Nikon görüntülerinde en yüksek doğruluğa (%0,874), YOLOv11l ise en yüksek duyarlılık değerine (%0,877) ulaşmıştır. Bu çalışma, dil modelleri ile üretilen görüntülerin gerçek dünya koşullarındaki

tarımsal uygulamalarda da yüksek doğruluk sağlayabildiğini kanıtlayarak, yapay görsel sentezin etiketli veri ihtiyacını önemli ölçüde azaltılabileceğini ve tarımsal robotik sistemlerin geliştirilme sürecini hızlandırabileceğini göstermektedir (Sapkota et al., 2024).

Khan ve Jensen (2024), tarımsal ıslah programlarının ve bitki fenotipleme süreçlerinin iyileştirilmesinde yaprak segmentasyonu ve sayımının oynadığı kritik rolü vurgulayarak, YOLOv11 tabanlı modellerin farklı tahıl türlerinde yaprak tespiti ve segmentasyonu konusundaki başarımını değerlendirmiştir. Çalışmada, ilkbahar arpası, ilkbahar buğdayı, kış buğdayı, kış çavdarı ve kış tritikale olmak üzere beş farklı bitki türü üzerinde hem birleşik hem de tür özelinde modellerin başarımı karşılaştırılmıştır. Nesne tespiti görevlerinde, birleşik modelin ilkbahar bitkileri için $mAP@50 > 0,85$, kışlık bitkiler için ise $> 0,7$ değerleriyle üstün performans gösterdiği saptanmıştır. Segmentasyon görevlerinde ise birleşik model genel doğrulukta başarılı olurken, bazı durumlarda tür özelinde eğitilmiş modellerin özellikle kışlık ürünlerde daha yüksek duyarlılık skorlarına ulaştığı görülmüştür. Elde edilen bulgular, veri seti çeşitliliğinin genelleme kabiliyetini artırdığını ortaya koymakta; ancak bireysel bitki türlerinin morfolojik farklılıkları nedeniyle özel modellerin hâlâ önemli katkılar sunabileceğini de göstermektedir. Bu çalışma, otomatik yaprak tespiti ve segmentasyonunda birleşik modellerin pratik avantajlarını ortaya koyarken, gerçek tarla koşullarındaki değişkenliği karşılayacak daha büyük ve dengeli etiketli veri kümelerinin gerekliliğine de dikkat çekmektedir. Böylece, model genellemesi ve tür özgünlüğü arasında denge kurularak, ileri düzey dijital fenotipleme sistemlerinin geliştirilmesi yönünde önemli bir adım atılmış olmaktadır (Khan & Jensen, 2024).

Rodríguez-Lira vd (2024), doğal çevre koşullarında Coleoptera zararlılarının neden olduğu fasulye yaprağı hastalıklarının doğru tanımlanmasına yönelik olarak, farklı YOLO mimarilerinin karşılaştırmalı analizini gerçekleştirmiştir. Çalışmada, doğal ortamlarda manuel olarak toplanan sağlıklı ve enfekte yaprak görüntülerinden oluşan veri seti, yaprak düzeyinde etiketlenmiş ve YOLOv5, YOLOv8, YOLOv9, YOLOv10 ve YOLOv11 modellerinin başarımı mAP metriğiyle değerlendirilmiştir. Elde edilen bulgular, özellikle YOLOv9e modelinin sınırlı örnek sayısına ve veri çeşitliliğine sahip veri setlerinde keskinlik ve duyarlılık arasında etkili bir denge kurarak en yüksek performansı sergilediğini ortaya koymuştur (Rodríguez-Lira et al., 2024).

Bitkilerde Su İhtiyacının Tespiti

Tarımsal üretimin sürdürülebilirliği, bitkilerin su ihtiyacının doğru belirlenmesi ve buna uygun sulama stratejilerinin geliştirilmesine bağlıdır. Bitkilerin büyüme dönemlerinde ihtiyaç duyduğu su miktarını ifade eden ET_c, hem toprağın buharlaşma kapasitesini hem de

bitkilerin terleme yoluyla su kaybını kapsamaktadır (Han et al., 2021). Bu nedenle, tarımda su yönetimi çalışmalarında ETc'nin doğru tahmini kritik bir öneme sahiptir. Özellikle su kıtlığı yaşanan bölgelerde, ETc'nin hatalı tahmini ya gereksiz su kullanımına ya da bitkinin kuraklık stresine girmesine neden olabilmektedir (M. Liu et al., 2023).

Tarihsel süreçte bitkisel su ihtiyacının tahmini için geliştirilmiş başlıca yöntemler arasında ampirik ve yarı ampirik modeller yer almaktadır. Penman-Monteith, Priestley-Taylor ve Blaney-Criddle gibi formüller, iklim verilerine dayalı olarak ETc tahmini yapan yaygın modeller arasında sayılmaktadır (Kashyap & Panda, 2001; Keabetswe et al., 2024; Qiu et al., 2019). Ancak bu modellerin doğru çalışabilmesi için sıcaklık, nem, rüzgar hızı ve güneşlenme gibi çok sayıda meteorolojik sensör verisine ihtiyaç duyması, pratikte uygulamayı zorlaştırmış ve bu alanda daha az veriyle çalışabilen teknolojilere olan ihtiyacı artırmıştır.

Bu ihtiyacı karşılamak amacıyla geliştirilen yeni nesil tahmin yaklaşımları arasında, yapay zekâ destekli algoritmalar öne çıkmaktadır. Özellikle YSA, zaman serisi analizi ve hibrit modellemeler, çoklu veri kaynaklarına ihtiyaç duymadan da ETc tahmininde başarılı sonuçlar elde edilebilmektedir (Keabetswe et al., 2024). Bunun yanında, görüntü işleme teknolojileri ile bitki morfolojisine dayalı değişkenlerin analiz edilmesi, literatürde giderek artan sayıda çalışmanın konusu olmuştur (Narendra Singh Chandel et al., 2024; Gautam et al., 2021).

Geleneksel yöntemlerin aksine, bu yeni yaklaşım doğrudan bitkiyi gözlemleyerek, görsel temelli çıkarımlar üzerinden sulama kararlarının verilmesini sağlamaktadır. Böylece hem sensör bağımlılığı azaltılmakta hem de bitki düzeyindeki bireysel su ihtiyacı daha hassas bir şekilde tespit edilebilmektedir. Son yıllarda bu amaçla kullanılan görüntü işleme destekli yöntemlerde, bitki su stresini belirlemek için yaprakların eğilme açısı gibi özgün morfolojik göstergelerden yararlanıldığı görülmektedir (Briglia et al., 2020; Zeyliger & Ermolaeva, 2021). Bu gelişmeler, özellikle düşük maliyetli IoT sistemleriyle birlikte çalışabilen algoritmaların tarımda yaygın kullanımına olanak tanımaktadır.

Uzaktan algılama teknolojilerindeki son gelişmeler, kaynakların sınırlı olduğu bölgelerde tarımsal uygulamalar için ETc tahminini önemli ölçüde geliştirmiştir. Uydu tabanlı enerji dengesi modellerinin entegrasyonu, yüzey sıcaklığı, bitki örtüsü endeksleri ve meteorolojik verileri analiz ederek gerçek ETc' nin doğru bir şekilde ölçülmesine olanak tanıyarak araştırmacıların ve tarımsal paydaşların mahsulün su ihtiyacını etkili bir şekilde izlemelerini sağlamıştır. Genellikle yerel veriler sunan geleneksel yöntemlerle karşılaştırıldığında, uydu yöntemleri heterojen arazilerdeki mekânsal değişkenliği hesaba katan kapsamlı bir görünüm sunmaktadır. Bu özellik, iklim değişikliği ve su kıtlığının

yarattığı artan zorluklar göz önüne alındığında avantajlıdır. Bu tür teknolojik uygulamalar sadece sulama uygulamalarını optimize etmekle kalmaz, aynı zamanda tarımsal üretkenliği sürdürülebilir su yönetimi ilkeleriyle uyumlu hale getirerek kurak ve yarı kurak bölgelerde gıda güvenliğini artırmaktadır (Woldemariam et al., 2025).

Bitkiler için optimum su gereksinimlerinin belirlenmesi, özellikle hem su basmasına hem de kuraklığa duyarlı tropikal iklimlerde su kaynaklarını etkin bir şekilde yönetirken tarımsal verimliliği artırmak için kritik öneme sahiptir. Toridi vd (2025) tarafından yapılan son araştırma, farklı büyüme aşamaları boyunca sulama ihtiyaçlarındaki değişkenliği yakalamak için CROPWAT modelini kullanarak meteorolojik veriler ve bitki büyüme parametrelerinin entegrasyonu yoluyla mahsul su ihtiyacı (CWR) tahminlerini geliştirmeye odaklanmaktadır. Çalışma, MetMalaysia tarafından derlenen 30 yıllık iklim verilerini analiz etmekte ve iklimsel aşırılıkların mısır üretimi üzerindeki olumsuz etkilerini azaltabilecek sulama yönetimi stratejilerini bilgilendirmek için ETc doğru bir şekilde tahmin edilmesinin önemini vurgulamaktadır. Bu yaklaşım sadece sulama uygulamalarının hassasiyetini arttırmakla kalmayıp, aynı zamanda tarımsal çıktıları dalgalı bir iklimin getirdiği zorluklar ışığında sürdürülebilir su yönetimi ilkeleriyle uyumlu hale getirmektedir (Mat Toridi et al., 2025).

Xu vd (2025) tarafından yapılan çalışma, İHA aracılığıyla multispektral uzaktan algılama teknolojilerinden yararlanarak Kuzeybatı Çin'in nemli bölgesindeki asmalar için bazal ürün katsayısını (K_{cb}) tahmin etmek için yeni bir yaklaşım sunmaktadır. Bu araştırma, etkili sulama yönetimi için önemli bir parametre olan K_{cb} 'yi elde etmek için toprak buharlaşma katsayısını (K_e) ve su stresi katsayısını (K_s) hesaplamayı içeren FAO-56 ikili ürün katsayısı yöntemini kullanmaktadır. İHA tarafından yakalanan multispektral görüntülerin kullanılması, üzüm spektral verilerinin çıkarılmasına olanak tanıyarak NDVI, Toprağa Göre Ayarlanmış Bitki Örtüsü İndeksi (SAVI), Oran Bitki Örtüsü İndeksi (RVI) ve Fark Bitki Örtüsü İndeksi (DVI) dahil olmak üzere çeşitli bitki örtüsü indekslerinin hesaplanmasını kolaylaştırır. Bu endeksler ile bazal ürün katsayısı arasında tek değişkenli doğrusal regresyon, polinom regresyon ve çoklu doğrusal regresyon yoluyla ilişkiler kurarak analiz etmişlerdir. Bulgular, hassas tarım uygulamalarına önemli ölçüde katkıda bulunarak, değişen iklim koşulları altında üzüm üretiminde su verimliliğini artırabilecek ve sulama stratejilerini optimize edebilecek bilgiler sağlamaktadır. K_{cb} için yapılan regresyon modelinde tüm büyüme aşamaları için 0,84 R^2 değeri elde etmişlerdir (Xu et al., 2025a).

Eludire vd (2025) , iklim değişikliğinin etkilerini azaltmak ve tarımsal üretimi optimize etmek amacıyla, manyok bitkisinin büyüme evreleri boyunca (başlangıç, gelişim,

orta ve geç dönemler) su kullanılabilirliğinin doğru değerlendirilmesinin önemine dikkat çekmiştir. Nijerya'nın Cross River havzasında yürütülen bu çalışmada, yağış ve ETc eğilimleri Mann–Kendall testi ile analiz edilmiştir. Yöntem olarak, Penman–Monteith, Blaney–Morin–Nigeria (BMN) ve Hargreaves–Samani (HAG) gibi üç ampirik metodu kullanılmıştır. Bununla birlikte, bu parametreleri YSA modelleri olan BMN-ANN ve HAG-ANN yapılandırmaları da geliştirilerek Penman–Monteith yöntemiyle karşılaştırılmıştır. 1979–2017 yıllarını kapsayan 39 yıllık uzaktan algılama meteoroloji verileri (CRU) ve manyok verimleri (IITA) temel alınarak yapılan analizlerde, yıllar içinde ETc değerlerinde anlamlı bir artış eğilimi gözlenmiştir. YSA modelleri, özellikle tahmin doğruluğu bakımından ampirik yöntemlere kıyasla üstün performans göstermiştir. BMN-ANN modeli, 3-3-1 ağ mimarisiyle (3 giriş nöronu, 3 gizli katman, 1 çıkış) en yüksek doğruluğu sağlamış; $R^2 = 0,9890$ ve $RMSE = 0,000056$ mm/gün gibi yüksek başarımlara ulaşmıştır. Aynı zamanda, gelişim döneminde günlük ortalama yaklaşık -1.1 mm/gün su açığı olduğu belirlenmiş; bu durumun kök biyokütlesi ve verim üzerinde olumsuz etkiler yaratabileceği vurgulanmıştır. Bu çalışma, uzun dönemli iklim verilerine dayalı olarak YSA modellerinin ETc tahmininde yüksek doğruluk sağladığını ve özellikle su kıtlığı ile mücadele edilen bölgelerde etkin sulama planlaması için güçlü bir araç sunduğunu göstermektedir. (Eludire et al., 2025).

Ferreira vd (2025) tarafından yürütülen araştırma, elma bahçelerinde su kullanımını tahmin etmek için uzaktan algılama teknolojisinin yenilikçi uygulamasına odaklanmaktadır. Bu çalışma, özellikle iklim değişkenliği geleneksel sulama uygulamalarını zorlamaya devam ederken, bahçecilikte etkili su yönetimi stratejilerinin önemini altını çizmektedir. Araştırmacılar, Mapping Evapotranspiration at High Resolution with Internalized Calibration (METRIC) yüzey enerji dengesi modelini kullanarak, gerçek evapotranspirasyonu (ETa) tahmin etmek için uzaktan algılama destekli bir yöntem türetmişlerdir. NDVI değerleri ile FAO tarafından önerilen Kc desenleri arasında yüksek bir uyum ($R^2 = 0,75$) gözlenmiş; bu da Kc tahmininde uzaktan algılama tabanlı yöntemlerin geçerliliğini desteklemiştir. Model, geleneksel yöntemlere kıyasla ETa tahmininde $\pm 0,3$ mm/gün'lük RMSE ve $0,6$ mm/gün⁻¹'lik düşük bir hata ile elde ederek umut verici sonuçlar ortaya koymuştur (Ferreira et al., 2025).

Moseki vd (2025) tarafından yürütülen çalışma, Namibya'nın yarı kurak koşullarında inci darısının (*Pennisetum glaucum*) değişen su rejimlerine karşı agro-fizyolojik ve morfolojik tepkilerini araştırmakta ve iklim değişikliği altında tarımda optimize edilmiş su yönetimine duyulan kritik ihtiyacı vurgulamaktadır. Araştırma, genellikle su kısıtlamalarına maruz kalan inci darı sistemlerinde büyüme ve verimi artırmak için tahmini ETc %75'inin uygulanmasının gerekli olduğunu vurgulamaktadır. Bulgular, inci darısının su stresi koşullarına önemli ölçüde

uyum sağladığını ve kurak ortamlarda dayanıklılığı artıran fizyolojik özellikler sergilediğini göstermektedir (Moseki et al., 2025).

Singh (2025) çalışmasında, Hindistan'ın Pencap eyaletinde 2023–2024 Kharif sezonunda çeltik ürününün su gereksinimini tahmin etmek amacıyla Sentinel-2 ve MODIS uydu verilerine dayalı bir uzaktan algılama çalışması yürütmüştür. Sentinel-2 görüntülerinden türetilen NDVI ile oluşturulan NDVI-Kc eğrisi, FAO referans yöntemleriyle yüksek korelasyon göstermiştir ($R^2 = 0.89$). Aynı şekilde, NDVI verileri kullanılarak tahmin edilen ETc ile Penman–Monteith yöntemiyle elde edilen referans ETc arasında güçlü bir doğrusal ilişki saptanmıştır ($R^2 = 0.97$ Sentinel-2 için, $R^2 = 0.95$ MODIS için) (Singh et al., 2025).

Bu kapsamlı bulgular, bitkisel üretimde su ihtiyacının doğru tahmin edilmesinin yalnızca verimlilik açısından değil, aynı zamanda sürdürülebilirlik, iklim uyumu ve gıda güvenliği hedefleri doğrultusunda da kritik bir rol oynadığını açıkça ortaya koymaktadır. Geleneksel yöntemlerin sınırlılıkları, yerini yapay zekâ, uzaktan algılama, görüntü işleme ve IoT gibi ileri teknolojilere bırakmakta; bu teknolojiler ise bölgesel iklim farklılıkları, mahsul türleri ve üretim ölçeklerine göre uyarlanabilir çözümler sunmaktadır. Literatürde sunulan güncel modeller, sulama yönetiminin yalnızca suyun fiziksel uygulanması değil, aynı zamanda agroekolojik dengenin korunması ve üretim planlamasında bilinçli karar alma süreçlerinin desteklenmesi açısından yeniden yapılandırılması gerektiğini göstermektedir. Bitki morfolojisine dayalı görsel analizler, multispektral görüntüleme teknikleri, yapay sinir ağları ve mikrometeorolojik modellemeler gibi araçlarla geliştirilen entegre yaklaşımlar, sadece bilimsel doğruluk değil, aynı zamanda tarımsal uygulamalarda pratik geçerlilik açısından da umut vadetmektedir. Sonuç olarak, gelecekteki su yönetimi stratejilerinde, bitki düzeyinde hassasiyetle geliştirilen veri tabanlı karar destek sistemleri, iklim krizine karşı tarımsal sistemlerin direncini artırmada vazgeçilmez olacaktır. Bu bağlamda, su kaynaklarının korunması ile tarımsal üretkenliğin artırılması arasında denge kuran teknolojik yeniliklerin yaygınlaştırılması, sürdürülebilir tarım politikalarının temel taşı olarak değerlendirilmelidir.

Kc Tahmininde Kullanılan Yöntemler ve Yapılan Çalışmalar

Bitkilerin toplam su ihtiyacını ifade eden ETc, etkili bir sulama yönetimi ve sürdürülebilir tarım uygulamaları açısından hayati bir parametredir. Ancak ETc'nin doğru tahmini, yalnızca iklim verilerine değil, aynı zamanda mahsul özelliklerini temsil eden ürün katsayısı (Kc) değerlerinin doğruluğuna da doğrudan bağlıdır. Kc, belirli bir bitki türünün referans evapotranspirasyona (ETo) göre ne ölçüde su kaybına uğradığını ifade eden bir katsayıdır ve bitkinin gelişim evrelerine, morfolojik özelliklerine ve çevresel koşullara göre değişkenlik göstermektedir. Dolayısıyla, Kc'nin eksik veya hatalı belirlenmesi, ETc

tahminlerinde zincirleme hatalara yol açarak ya gereğinden fazla sulamaya ya da yetersiz su teminine neden olabilmektedir. Bu durum yalnızca verim kayıplarına değil, aynı zamanda su kaynaklarının israfına ve toprak-sağlık dengesinin bozulmasına da sebebiyet verebilir. Günümüzde artan iklim değişkenliği, kuraklık tehdidi ve tarımsal girdilerin maliyeti göz önünde bulundurulduğunda, Kc değerlerinin doğru, dinamik ve bitkiye özgü biçimde tahmin edilmesi, su yönetimi stratejilerinin başarısı için kritik bir gereklilik hâline gelmiştir. Bu bağlamda, geleneksel sabit Kc tablolarının yerini, bitki örtüsü indekslerine, uzaktan algılama verilerine, yapay zekâ tabanlı modellemelere ve görüntü işleme tekniklerine dayalı güncel tahmin yöntemleri almaya başlamıştır. Aşağıda sunulan bölümde, Kc tahmini üzerine yapılmış çalışmalar incelenecek ve bu yöntemlerin ETc tahminine katkıları değerlendirilecektir.

Tunalı vd (2023) tarafından gerçekleştirilen çalışma, kapalı topraksız tarım sistemlerinde domates bitkileri için Kc tahminine odaklanarak, YSA modellerinin bu alandaki potansiyelini ortaya koymaktadır. Araştırmada, geleneksel yöntemlerle belirlenmesi zaman alıcı ve çok sayıda iklim verisi gerektiren Kc değerlerinin, sınırlı meteorolojik veri ile yüksek doğrulukta tahmin edilebildiği gösterilmiştir. YSA modellemesi sayesinde, domates bitkisinin farklı gelişim evrelerine uygun olarak Kc'nin dinamik biçimde tahmin edilmesi sağlanmış ve bu durum, ETc hesaplamalarının güvenilirliğini artırarak sulama planlamasında daha hassas uygulamaların önünü açmıştır (Tunalı et al., 2023).

Sabie vd (2024) çalışmalarında, tarla ölçeğinde ETc uzaktan algılama yoluyla tahmini için bitki indekslerine dayalı ürün katsayısı (K_{cVI}) modellerinin geliştirilmesinde Harmonize Landsat Sentinel-2 (HLS) veri setinin potansiyelini incelemişlerdir. Yüksek mekânsal (30 m) ve kısa zamansal (<5,7 gün) çözünürlük sunan HLS verileri, özellikle sulama zamanlamasının iyileştirilmesi, su koruma programlarının izlenmesi ve verimliliğin artırılması açısından kritik öneme sahiptir. Araştırmada, New Mexico'daki Mesilla Vadisi'nde yetiştirilen yonca bitkisine ait arazi bazlı ET verileriyle ilişkilendirilmek üzere HLS verileri kullanılarak on altı farklı bitki indeksi hesaplanmış ve bu indekslerle K_{cVI} modelleri oluşturulmuştur. Elde edilen doğrusal modellerin tamamı, Kc değerleriyle yüksek uyum göstermiş ($R^2 = 0,67-0,90$; $RMSE = 0,17-0,09$) ve ETc tahminlerinde kabul edilebilir hata oranlarına ulaşılmıştır (MAE: 0,35–0,64 mm/gün; MSE: 0,20–0,75 mm/gün; MAPD: %10,0–16,5). Özellikle gelişim döneminin başında ve biçim zamanlarında, spektral sinyalin toprak arka planı ve sulama gibi dış etkenlerden etkilenmesi nedeniyle model doğruluğunda görece azalma gözlemlenmiştir (Sabie et al., 2024).

Fuente-Sáiz vd (2024), su kaynaklarının sınırlı olduğu bölgelerde sulama yönetiminin optimize edilmesine yönelik olarak ETa ve Kc doğru bir şekilde tahmin edilmesinin önemine dikkat çekmişlerdir. Araştırmada, uydu tabanlı METRIC modelini, seyrek örtülü bitki yapısına sahip elma bahçelerinde (damla sulamalı) üç üretim sezonu boyunca (2012/13, 2013/14, 2014/15) uygulanmıştır. Akdeniz iklim koşullarında yürütülen bu çalışmada, METRIC modeline yaprak alan indeksi (LAI), yüzey pürüzlülüğü (Z_{om}) ve toprak ısı akısı (G) gibi parametreleri kapsayan kalibre edilmiş alt modeller entegre edilerek ETa ve Kc değerleri tahmin edilmiştir. Bu tahminler, saha koşullarında elde edilen Eddy Covariance ölçümleri ile doğrulanmış ve modelin Kc ile ETa'yı %10'dan daha az hata ile aşırı tahmin ettiği belirlenmiştir. Bulgular, METRIC modelinin meyve bahçesi gibi seyrek bitki örtüsüne sahip alanlarda kalibre edilerek kullanılması durumunda, ETa ve Kc tahminlerinde yüksek doğruluk sağlayabildiğini ve sulama karar destek sistemlerinde güvenilir bir araç olarak kullanılabileceğini göstermektedir. Bu çalışma, uzaktan algılama tabanlı modellerin yalnızca geniş ve homojen tarım arazileri için değil, aynı zamanda meyve yetiştiriciliği gibi daha karmaşık ve heterojen sistemlerde de etkili bir şekilde uygulanabileceğini ortaya koyarak, modelin alan uyarlamasının önemini vurgulamaktadır (de la Fuente-Saiz et al., 2024).

Cheema vd (2025) çalışmalarında, makine öğrenimi tekniklerinin entegrasyonu yoluyla patates için Kc tahminine bir metodoloji sunmaktadır. Bu araştırma, genellikle mevcut agronomik koşulları doğru bir şekilde yansıtmayabilecek ampirik verilere dayanan geleneksel ürün katsayılarını tahmin etme yöntemleriyle ilgili zorlukları ele almaktadır. Araştırmacılar, Kc tahmini için, Kaotik Oyun Algoritması (Chaos Game Optimization) ile optimize edilmiş XGBoost algoritması (CGO-XGBoost) kullanılmış ve üç farklı girdi senaryosu (meteorolojik + toprak verileri, yalnızca toprak verileri, yalnızca meteorolojik veriler) denenmiştir. Ayrıca geliştirilen bu modelin performansı, diğer üç makine öğrenme algoritması olan K-en yakın komşu (KNN), Uyarlamalı Artırma (AdaBoost) ve Çok Katmanlı Algılayıcı Sinir Ağı (MLP) ile karşılaştırılmıştır. Elde edilen bulgular, CGO-XGBoost modelinin geleneksel yöntemlere kıyasla üstün bir doğruluk sergilediğini ortaya koymuştur. Girdi senaryoları açısından değerlendirildiğinde, yalnızca toprak verilerinin kullanıldığı senaryonun en başarılı tahminleri sağladığı, yalnızca meteorolojik verilerin kullanıldığı senaryonun ise en düşük başarıyı gösterdiği belirlenmiştir. En yüksek doğruluk, toprak verilerinin CGO-XGBoost ile birlikte kullanıldığı modelde elde edilmiştir ($R = 0,9961$, $RMSE = 0,0185$, $MAPE = \%2,20$) (Cheema et al., 2025).

Tegegne vd (2025), değişen iklim koşullarında tarımsal üretkenliğin artırılması ve su kaynaklarının sürdürülebilir yönetimi açısından mevcut ve gelecekteki bitki su ihtiyacının

doğru bir şekilde öngörülmesinin önemini vurgulamaktadır. Etiyopya'nın Lemo bölgesinde 2016–2017 yıllarında yürütülen saha denemelerinde, lahana ve havuç bitkileri için sulama karar destek araçları kullanılarak bitki su ihtiyacına ilişkin veriler toplanmıştır. Toprak su dengesi yöntemiyle elde edilen Kc değerleri, APEX (Agricultural Policy Environmental eXtender) modeliyle simüle edilen Kc sonuçlarıyla karşılaştırılmıştır. Saha verilerine göre, çiftçilerin geleneksel uygulamaları, nem algılayıcı temelli sulama yöntemlerine (WFD) kıyasla daha fazla su kullanmıştır. APEX modeli tarafından üretilen simülasyon sonuçları, FAO tarafından belirlenen Kc desenleriyle uyum göstermiş ve modelin performansı R^2 değerleriyle (lahana için 0,5–0,75; havuç için 0,66–0,96) desteklenmiştir. Ayrıca, iklim değişikliği senaryoları altında, büyüme dönemindeki potansiyel evapotranspirasyonun sırasıyla 2025, 2055 ve 2085 yıllarında %2,5, %5,1 ve %6,0 oranında artacağı öngörülmüştür. Bu değişimlere paralel olarak, 2085 yılı için simüle edilen Kc değerlerinin varyasyon katsayısı lahana için %19, havuç için %24 olarak belirlenmiş, bu da gelecekteki belirsizliğin daha yüksek olabileceğini göstermektedir. Çalışmanın bulguları, iklim değişikliği bağlamında su talebindeki artışın dikkate alınarak sulama planlamalarının yeniden yapılandırılması gerektiğine işaret etmektedir. Bu yönüyle araştırma, sadece mevcut sulama uygulamalarının değerlendirilmesine değil, aynı zamanda uzun vadeli tarımsal su yönetimi stratejilerinin geliştirilmesine de katkı sunmaktadır (Tegegne et al., 2025).

Reta vd (2025), Etiyopya'nın Arba Minch bölgesinde karpuz tarımı için bitki su ihtiyacının daha doğru tahmin edilebilmesine yönelik olarak uyarlanmış çift ürün katsayısı yaklaşımının ve AquaCrop modelinin geçerliliğini incelemektedir. AquaCrop modeli Etc, buharlaşma ve terleme bileşenlerini başarıyla simüle etmiş; modelin doğruluk düzeyi $R^2 = 0,84$ ve $NSE = 0,74$ değerleriyle teyit edilmiştir. Bu bağlamda araştırma, gelişmiş Kc modelleri ile saha yönetimi uygulamalarının birleşiminin, su kaynaklarının sürdürülebilir yönetimi ve iklim değişikliğine uyum çabaları açısından önemli katkılar sağlayabileceğini ortaya koymaktadır (Reta et al., 2025).

Dong vd (2025), Çin'in Sarı Nehir Deltası'nın tuzlu-alkali topraklarında başlıca ürünler olan buğday, mısır ve soya fasulyesi için su gereksinimlerini tahmin etmeyi amaçlayan Kc yaklaşımları ve makine öğrenimi modellerinin karşılaştırmalı bir analizini yapmıştır. Araştırma, özellikle toprak-su-ürün etkileşimlerinin karmaşık olduğu ortamlarda, FAO-56 kılavuzunda önerilen geleneksel Kc tahmin yöntemlerinin doğasında bulunan sınırlamaları vurgulamaktadır. Bu zorluklar, bu tür bölgelerde etkili su yönetimi için kritik öneme sahip olan Etc tahminlerini geliştirmek için gelişmiş metodolojilerin araştırılmasını gerektirmektedir. Araştırmacılar hem tek hem de çift ürün katsayısı metodolojilerine karşı

etkinliklerini değerlendirmek için üç makine öğrenimi algoritması Gradient Boosting Decision Tree (GBDT), rastgele orman (RF) ve aşırı gradyan artırma regresyonu (XGBoost)) uygulamıştır. Elde edilen bulgular, makine öğrenimi tabanlı modellerin Kc-ETo yöntemlerine göre önemli ölçüde daha düşük hata payı ile (ortalama mutlak hata %26.4–%80.9 oranında azalmış), daha yüksek açıklayıcılık gücüyle (R^2 %5,6–%11,2 artmış) (R^2 0,911-0,997) ve daha düşük RMSE değerleriyle (%22,4–%98,1 arası azalma) üstün performans gösterdiğini ortaya koymuştur (Dong et al., 2025).

Tüm bu çalışmaların ortak noktası, Kc tahmininin tarımsal su yönetiminde ne denli kritik bir rol oynadığını ortaya koymalarıdır. Geleneksel sabit Kc tablolarının, çevresel değişkenliği ve bitki türüne özgü özellikleri yeterince yansıtamaması, uzaktan algılama teknolojileri, yapay zekâ temelli modellemeler ve makine öğrenimi gibi yenilikçi yöntemlere yönelimi hızlandırmıştır. İHA destekli görüntü analizlerinden spektral indekslere, akıllı sulama sistemlerinden AquaCrop ve FAO-56 tabanlı algoritmalara kadar uzanan çok çeşitli yöntemler hem zamansal hem de mekânsal düzeyde yüksek doğrulukta Kc tahminlerine ulaşılmasını mümkün kılmaktadır. Özellikle değişken iklim koşulları, su kıtlığı ve farklı büyüme ortamları gibi karmaşık sorunlara karşı geliştirilen bu modeller, yalnızca ETC tahminlerinin hassasiyetini artırmakla kalmamakta; aynı zamanda su kaynaklarının etkin kullanımını, tarımsal üretkenliği ve sürdürülebilirliği destekleyici güçlü araçlar olarak öne çıkmaktadır. Dolayısıyla Kc tahminine yönelik geliştirilen bu çok disiplinli yaklaşımlar, modern tarımda dijital dönüşümün ve veri odaklı yönetimin vazgeçilmez bir parçası hâline gelmiştir. Bu bağlamda, tarımsal karar destek sistemlerinin merkezine yerleşen Kc tahmini, sadece verim odaklı değil, aynı zamanda iklim uyumlu ve çevresel sorumluluk taşıyan üretim modellerinin de temelini oluşturmaktadır.

Mahsul Su Stresi Tahmini için Yapılan Çalışmalar

Tarımda verimlilik, yalnızca yeterli su teminiyle değil, aynı zamanda bitkilerin suya ulaşımında yaşadığı stres düzeyinin doğru bir şekilde izlenmesiyle de yakından ilişkilidir. Bitkilerde su stresi, fizyolojik süreçlerin bozulmasına, fotosentez hızının düşmesine, büyümenin yavaşlamasına ve sonuç olarak ürün kalitesi ile veriminde azalmaya neden olan ciddi bir durumdur. Özellikle iklim değişikliği, artan sıcaklıklar ve düzensiz yağış rejimleri, tarımsal alanlarda su stresinin sıklığını ve şiddetini artırmakta; bu durum, su yönetimi stratejilerinin yeniden yapılandırılmasını zorunlu kılmaktadır. Bu bağlamda, su stresinin erken teşhisi ve doğru tahmini hem sulama zamanlamasının hem de miktarının belirlenmesinde kritik bir rol oynamaktadır. Literatürde su stresinin tespitine yönelik geliştirilen yöntemler; yaprak su potansiyeli, stomatal iletkenlik, bitki sıcaklığı, klorofil floresansı gibi fizyolojik

göstergelerin doğrudan ölçümüne dayalı biyofiziksel yaklaşımların yanı sıra; uzaktan algılama, hiperspektral görüntüleme, termal kamera sistemleri ve yapay zekâ algoritmalarına dayalı teknolojik sistemlerle de desteklenmektedir. Ayrıca, son yıllarda gelişen makine öğrenimi modelleri ve görüntü işleme teknikleri sayesinde, bitki morfolojisindeki değişikliklerin analiz edilerek su stresinin otomatik ve yüksek doğrulukla tahmin edilmesi mümkün hâle gelmiştir. Bu bölümde, literatürde su stresi tahmini üzerine yapılmış güncel çalışmalar detaylı şekilde ele alınarak, kullanılan yöntemlerin temel dayanakları, karşılaşılan sınırlılıklar ve tarımsal uygulamalara sağladığı katkılar sunulmuştur.


Literatürdeki birçok güncel çalışmada Bitki Su Stresi İndeksi'nin (Crop Water Stress Index – CWSI) tarımsal su yönetiminde etkili bir araç olarak kullanıldığı görülmektedir (Gültaş, 2025; Kapari et al., 2025; Mao et al., 2025; Workneh et al., 2025; H. Zhang et al., 2025). CWSI, özellikle buharlaşma, terleme, yaprak sıcaklığı ve atmosferik koşullara dayalı parametreleri bir araya getirerek, bitkilerin maruz kaldığı su stresinin nicel olarak değerlendirilmesini sağlamaktadır. Bu yöntem, farklı iklim koşullarında ve sulama rejimlerinde stres düzeylerinin belirlenmesinde yüksek açıklayıcılık gücüne sahiptir ve karar destek sistemlerine entegre edilebilme potansiyeliyle ön plana çıkmaktadır. Ancak, CWSI hesaplamaları için gerekli olan meteorolojik verilerin temini, sensör tabanlı ölçümler ve karmaşık hesaplama süreçleri, bazı saha uygulamalarında sınırlayıcı olabilmektedir. Bu nedenle, özellikle görüntü işleme ve yapay zekâ destekli yaklaşımlar yoluyla, doğrudan bitki görselleri üzerinden su stresinin belirlenmesine duyulan ihtiyaç her geçen gün artmaktadır. Görsel tabanlı sistemler, yaprak sararması, yaprak kıvrılması, renk değişimi ve büyüme duraklaması gibi stres belirtilerini otomatik olarak analiz ederek, daha erişilebilir ve hızlı bir değerlendirme imkânı sunabilir. Bu durum, hem zaman hem de maliyet açısından daha sürdürülebilir çözümler geliştirilmesine katkı sağlayabilir.

Ahmad vd (2021), artan küresel rekabet, ürün hastalıkları ve bitki su stresi gibi tarımsal üretim risklerinin, hassas tarım sistemleri ve uzaktan algılama teknolojilerinin entegrasyonu yoluyla yönetilebileceğini savunmaktadır. Çalışma, bitki su stresinin belirlenmesine yönelik olarak geliştirilen yeni yöntemleri ve bu stresin ölçülebilir bazı parametrelerle olan ilişkisini irdelleyen kapsamlı bir derleme niteliğindedir. Uzaktan algılama sistemlerinin farklı ekolojik bölgelerdeki karmaşık bitki-su ilişkilerini sade ve etkili biçimde değerlendirme kapasitesine sahip olduğu vurgulanmış, özellikle zamansal duyarlılığı yüksek çözümler üretme potansiyeline dikkat çekilmiştir. İlk olarak, görelî su içeriği (RWC), eşdeğer su kalınlığı (EWT) ve toprak nemi gibi ölçütlerin bitki su stresiyle olan ilişkisi ele alınmış; ardından, ET_c ve güneş kaynaklı klorofil floresansı gibi parametrelerin uzaktan algılama

yoluyla su stresi deęerlendirmesinde nasıl kullanılabileceęi tartıřılmıřtır. alıřmada ayrıca, optik algılama sistemleri, termometrik algılayıcılar, arazi yüzey sıcaklıęı ölçüm sistemleri, ok bantlı (uzay ve hava tabanlı) algılama sistemleri, hiperspektral görüntüleme ve LiDAR gibi farklı uzaktan algılama teknolojileri detaylı biçimde tanıtılmıřtır (Ahmad et al., 2021).

Günümüzde, bitkilerin biyofiziksel parametreleri ve fizyolojik durumları hakkında bilgi edinmek amacıyla hava araçlarıyla yapılan uzaktan algılama uygulamalarında kullanılan veriler arasında yaprak alan indeksi (LAI), biyokütle, klorofil/karoten içerikleri ile bitki su durumu (örneğin stomal iletkenlik ve yaprak su potansiyeli) yer almaktadır. Görüntülemeye dayalı uzaktan algılama sistemleri, temel olarak görünür ışık (RGB: kırmızı, yeřil, mavi), kızılötesi (IR) ve uzak kızılötesi (termal) bantlardaki yaprak ve bitki örtüsü yansımalarını ölçmektedir.

Yaprak yansıma özellikleri, bitki fizyolojisinin bir göstergesi olarak deęerlendirilebilir; ünkü bu yansımalar, doğrudan yaprağın pigment bileřimiyle (örneğin klorofil ve ksantofiller) ilişkilidir ve dolayısıyla bitkinin fizyolojik durumunu yansıtabilir. Bitki örtüsü endeksleri, **řekil 3**'te verildięi gibi genellikle RGB ve IR gibi geniş bantlara ek olarak spektrumun daha dar aralıklarındaki yansıma bantlarına dayalı olarak oluřturulmaktadır. Bu tür yansımaların ölçümünde oęunlukla görünür, multispektral ve hiperspektral kameralar kullanılmaktadır (Gago et al., 2015).




řekil 3. Bitki örtüsü endekslerinden NDVI (bantlar 6, 3 ve 4), TCARI/OSAVI (bantlar 1, 4, 5 ve 6), PRI (bantlar 1 ve 2) ve PRI_{norm} (bantlar 1, 2, 4, 5 ve 6) ile termal endekslerden CWSI (bant 7) hesaplamalarında kullanılan yaprak spektral yansıması ve termal bandı içeren elektromanyetik spektrum bileřenleri gösterilmektedir.

En yaygın kullanılan endekslerden biri NDVI olup, yaklaşık 800 nm'deki yakın kızılötesi (NIR) yansıma ile yaklaşık 680 nm'deki kırmızı (R) yansıma değerleri temel alınarak hesaplanmaktadır. Başlangıçta Landsat uydu sensörlerinin bantlarına göre geliştirilmiş olan bu endeks, klorofillerin yüksek kızılötesi yansıma özelliğinden yararlanarak bitkilerin yapısal özelliklerini ve yeşil örtüsünü tespit etmek amacıyla sıklıkla kullanılmaktadır. Çok sayıda çalışma, buğday, mısır ve zeytin gibi otsu ve odunsu bitkilerde LAI'nin belirlenmesinde NDVI'nin kullanılabilirliğini ortaya koymuş; bu tür uygulamalarda çok bantlı kameralarla donatılmış insansız hava araçlarının (İHA) etkinliğini vurgulamıştır.

Chandel vd (2021) , küresel gıda güvenliği ve sürdürülebilir tarım hedefleri doğrultusunda bitki su stresinin zamanında ve etkili bir şekilde tespit edilmesinin kritik önem taşıdığını vurgulamaktadır. Geleneksel yöntemlerin çoğu, doğrudan ya da dolaylı ölçüm tekniklerine dayanmakta olup yüksek hassasiyetli sensörlere, uzmanlık bilgisine ve zaman alıcı laboratuvar süreçlerine ihtiyaç duymaktadır. Bu zorlukları aşmak amacıyla yürütülen söz konusu çalışmada, görüntü işleme teknikleri ile derin öğrenme (DL) modellerinin entegrasyonu yoluyla mısır (*Zea mays*), bamya (*Abelmoschus esculentus*) ve soya fasulyesi (*Glycine max*) bitkilerinde su stresinin tespiti amaçlanmıştır. Çalışmada AlexNet, GoogLeNet ve Inception V3 olmak üzere üç farklı DL modelinin karşılaştırmalı performansı değerlendirilmiş; her bir bitki türü için 1200 dijital görüntü kullanılarak modeller eğitilmiştir. Sonuçlar, özellikle GoogLeNet mimarisinin su stresini belirlemede en yüksek doğruluğa sahip olduğunu göstermiştir (mısır için %98,3, bamya için %97,5 ve soya için %94,1). Bu çalışma, görüntü işleme tabanlı makine öğrenmesi uygulamalarının geleneksel su stres tespit yöntemlerine kıyasla daha hızlı, etkili ve sahada uygulanabilir çözümler sunduğunu ortaya koyarak, tarımsal izleme ve akıllı sulama sistemlerinin dijitalleşmesine katkı sağlamaktadır (Narendra Singh Chandel et al., 2021a).

Rossi vd (2022), **Şekil 4**'te şematigi verilen çalışmalarını, çevresel stres koşullarına karşı bitki tepkilerinin yüksek doğrulukla ve çok yönlü olarak analiz edilmesini sağlayan görüntü tabanlı, fenotipleme sistemini kurmuşlardır. Çalışmada, üç boyutlu (3D) modelleme ve Yapıdan Hareketle Görüntüleme (Structure from Motion – SfM) yöntemi temel alınarak geliştirilen yeni bir segmentasyon algoritması aracılığıyla, domates bitkilerinde morfolojik özelliklerin otomatik olarak belirlenmesi hedeflenmiştir. Algoritma, bitki boyu ($R^2 = 0,98$, MAE = 0,34 cm), yaprak sapı eğim açısı ($R^2 = 0,96$, MAE = 1,35°), tek yaprak alanı ($R^2 = 0,98$, MAE = 0,95 cm²) ve tek yaprak açısı ($R^2 = 0,84$, MAE = 1,43°) gibi temel fenotipik parametrelerin yüksek doğrulukla ölçümünü sağlamıştır. Segmentasyon sonuçları duyarlılık %94,48, keskinlik %97,55 ve F1 %95,74 olarak elde edilmiştir. Uygulama örneği olarak, bu


algoritma 20 gün boyunca üç farklı sulama rejiminde (tam sulama, %50 kısıtlı sulama ve susuz bırakma) yetiştirilen domates çeşitlerinin su stresine karşı dinamik tepkilerini değerlendirmek üzere kullanılmıştır. Elde edilen bulgular, bitki boyunun su stresine duyarlılık açısından etkili bir erken gösterge olarak kullanılabileceğini ve bu özelliğin, kuraklığa dayanıklı domates çeşitlerinin ıslahında seçici bir ölçüt olarak değerlendirilebileceğini ortaya koymaktadır. Bu çalışma, yüksek verimli fenotipleme platformlarının, ileri düzey bitki izleme, stres analizi ve ıslah programlarında yenilikçi bir araç olarak kullanım potansiyelini güçlendirmektedir (Rossi et al., 2022).



Şekil 4. Rossi vd (2022) çalışmasında kullandığı deney sisteminin şematik gösterimi.

Briglia vd (2020), çevresel stres koşullarına karşı bitkilerin hızlı morfolojik tepkilerini değerlendirmede görüntü tabanlı yaklaşımların potansiyelini ortaya koyan bir çalışma yapmışlardır. **Şekil 5**'te görüldüğü üzere asma bitkisinin yaprak açı profilinde çıkarıp, burada meydana gelen değişiklikleri ilerleyici kuraklık koşulları altında hem manuel yöntemle (gonyometre) hem de 3B görüntüleme teknikleri (çoklu görüş stereo ve yapıdan hareketle modelleme – SfM) ile ölçülmüştür. Deneme süresince, bitkiler %100 (CTRL), %60 (IRR60%) ve %30 (IRR30%) toprak nem kapasitesine karşılık gelen sulama seviyelerine maruz bırakılmış; eş zamanlı olarak stomatal iletkenlik, yaprak su potansiyeli, klorofil floresansı (Fv/Fm), yaprak alanı ve 2B RGB görüntü verileri toplanmıştır. Yaprak su potansiyeli değerleri -0.4 (CTRL) ile -1.1 MPa (IRR30%) arasında değişmiş; bu değişkenin yaprak açısıyla doğrusal ilişkisi, hem manuel ölçümlerde ($R^2 = 0,86$) hem de 3B görüntülerle ($R^2 = 0,73$) ortaya koymuştur. Kuraklık koşullarında özellikle IRR30% grubunda stomatal iletkenlik ve yaprak büyümesi belirgin şekilde azalmış, ancak fotosentetik kapasite (Fv/Fm)

etkilenmemiştir. Ayrıca, başka bir deneysel düzende geliştirilen piksel sayısına dayalı yaprak alanı tahmin modeli başarıyla uygulanmış ($R^2 = 0,78$); 2B üstten görüntülerle yeşil alan oranında (GGF) CTRL ve IRR60% gruplarında %50'ye varan azalma görülürken, IRR30% grubunda %20'lik bir artış kaydedilmiştir. Bu çalışma, yaprak açısı ve yeşil alan oranı gibi görsel parametrelerin, bitki su durumunun temas gerektirmeyen, yüksek verimli ve zamana bağlı izlenmesi açısından güvenilir biyobelirteçler olduğunu göstermekte; bu bulgular, su stresi tespitinde klasik yöntemlere tamamlayıcı nitelikte yeni nesil görüntüleme tabanlı çözümlere duyulan ihtiyacın altını çizmektedir (Briglia et al., 2020).



Şekil 5. Briglia vd (2020) yaprak açısını belirlemek için kullanılan protokolün şematik diyagramı.


Sonuç olarak, tarımda su stresinin erken, doğru ve sürdürülebilir şekilde tespiti, yalnızca verim artışını değil, aynı zamanda iklim değişikliğine uyum ve kaynakların etkin kullanımını da beraberinde getiren çok boyutlu bir gerekliliktir. Literatürde CWSI gibi termal tabanlı indekslerin sağladığı yüksek açıklayıcılık gücüne rağmen, bu yöntemlerin saha uygulamaları için gereken veri ve donanım gereksinimleri çeşitli sınırlılıklar doğurabilmektedir. Buna karşılık, görüntü işleme ve yapay zekâ tabanlı sistemlerin; bitki yaprak morfolojisi, renk değişimleri ve üç boyutlu yapısal tepkiler gibi görsel parametreler üzerinden su stresini hızlı, maliyet-etkin ve temassız olarak değerlendirme potansiyeli giderek

artmaktadır. RGB, multispektral, hiperspektral ve termal görüntüleme tekniklerinin fenotipleme platformlarına entegre edilmesiyle hem doğruluk düzeyi yükselmekte hem de uygulama alanı genişlemektedir. Bu teknolojik gelişmeler, klasik fizyolojik ölçümlere olan bağımlılığı azaltırken, büyük ölçekli tarımsal izleme sistemlerinin temellerini de güçlendirmektedir. Gelecekte, görüntü tabanlı ve yapay zekâ destekli su stresi analizlerinin, tarımsal karar destek sistemlerine entegre edilerek akıllı sulama stratejilerinin merkezine yerleşeceği öngörülmektedir. Bu bağlamda, bitki görsellerinden elde edilen verilerin kullanımı hem araştırmacılar hem de uygulayıcılar için yeni ufuklar açmakta; su stresi yönetiminde yeni bir paradigma oluşturmaktadır.



MATERYAL VE YÖNTEM

Bu bölümde, bitkisel üretimde su yönetiminin iyileştirilmesine yönelik olarak geliştirilen görüntü işleme destekli tahmin modelinin oluşturulmasında izlenen deneysel tasarım, veri toplama stratejileri ve analiz süreçleri ayrıntılı biçimde sunulmaktadır. Araştırmada, Doğu Anadolu Bölgesi'nin tipik karasal iklim koşulları altında yürütülen açık alan deneylerinde, su stresine duyarlı bir tür olan fasulye bitkisi tercih edilmiş ve bu bitki üzerinden farklı sulama düzeylerinin morfolojik etkileri değerlendirilmiştir. Sulama düzeylerinin belirlenmesinde, Türkiye Cumhuriyeti Tarım ve Orman Bakanlığı tarafından geliştirilen SUET (Sulama Yönetimi ve Bitki Su Tüketimi Hesaplama Sistemi) programı kullanılmış; ET_c değerlerine dayalı olarak %100, %75, %50 ve %25 oranlarında dört farklı uygulama grubu oluşturulmuştur. Geliştirilen IoT sistemi kapsamında, her parsel için ayrı yapılandırılan damla sulama sistemleri ve mikrodenetleyici tabanlı ölçüm birimleri entegre edilerek, çevresel ve fizyolojik verilerin senkronize biçimde toplanması sağlanmıştır. Görüntü verileri, 2 MP çözünürlüğe sahip OV2640 kameraları ile alınmış ve Firebase bulut sistemine aktarılmıştır. Elde edilen görseller, YOLOv12 algoritması kullanılarak segmentasyon ve poz tahmini işlemlerine tabi tutulmuş; bu süreçte yaprak, meyve, gövde gibi bitki bileşenleri ayrıştırılmış ve yaprak eğilme açısı gibi kritik stres göstergeleri hesaplanmıştır. Segmentasyon maskeleri yardımıyla elde edilen morfolojik özellikler, YSA modeli ile işlenerek bitkisel ET_c ve K_c değerleri tahmin edilmiştir. Ayrıca, model başarımı, hem YOLOv12'ye ait nesne tanıma metrikleri (Precision, Recall, F1, mAP@50) hem de YSA tahmin çıktıları için hesaplanan RMSE, MAPE ve R² gibi performans göstergeleriyle kapsamlı olarak değerlendirilmiştir. Bu sistematik yaklaşım, sensörsüz tarım uygulamalarında görüntü tabanlı karar destek sistemlerinin uygulanabilirliğini ortaya koymayı hedeflemektedir. Önerilen yöntemin akış diyagramı **Şekil 6**'da verilmiştir.




Şekil 6. Önerilen yöntemin akış diyagramı

IoT Sisteminin Kurulması ve Veri Setinin Toplanması

Deneyin yürütüldüğü alan, Türkiye'nin Doğu Anadolu Bölgesi'nde yer almakta olup, bölgenin belirgin karasal iklim koşulları deneyin planlanmasında ve bitki türü seçiminde önemli rol oynamıştır. Türkiye Cumhuriyeti Meteoroloji Genel Müdürlüğü'nün 2024 yılına ait uzun dönemli meteorolojik verilerine göre, bu bölgede yıllık ortalama sıcaklık 6,2 °C, ortalama günlük güneşlenme süresi 6,3 saat, yıllık ortalama yağışlı gün sayısı 118,1 ve aylık toplam yağış miktarı ortalaması 524,9 mm olarak rapor edilmiştir. Bu iklimsel veriler, özellikle büyüme dönemi boyunca yaşanabilecek su yetersizlikleri ve düşük sıcaklık riski nedeniyle, tarımsal üretim için sınırlandırıcı koşullar oluşturmaktadır. Bu bağlamda hem kuraklığa duyarlılığı yüksek hem de fizyolojik tepkileri belirgin şekilde gözlemlenebilen bir tür olan fasulye deney bitkisi olarak tercih edilmiştir. Fasulyenin bu bölgeye ekolojik uyumu, literatürde su stresine karşı verdiği morfolojik ve fizyolojik yanıtların açıkça tanımlanmış olmasıyla da desteklenmiştir.


Deneysel sürecin ilk aşaması, kontrollü çevre koşullarında yürütülen ön çalışma ile başlatılmıştır. Bu aşamada, Şekil 7'de sunulan sistem kurulmuş ve her bir sulama düzeyi için dört tekrardan oluşan toplam sekiz saksı yerleştirilmiştir. Her saksı bir bitki içerecek şekilde tasarlanmış olup, sulama sistemi, görüntü toplama sistemi ve veri aktarım birimleri entegre

edilerek deney düzeneği denenmiştir. Bu ön uygulama ile IoT tabanlı sistemin çalışma verimliliği test edilmiş, sulama ve görüntüleme bileşenlerinin işlevselliği doğrulanmış ve deneysel protokolün tarla koşullarına ölçeklenebilirliği değerlendirilmiştir.



Şekil 7. Saksı dikimi ile ön çalışma sistemi

Ön çalışmadan elde edilen veriler doğrultusunda sistemin güvenilirliğinin sağlanmasının ardından, ana deney aşamasına geçilmiş ve açık tarla uygulamaları başlatılmıştır. Tarla deneyi, **Şekil 8**'de görüldüğü üzere, klasik sıralı ekim düzenine uygun olarak gerçekleştirilmiştir. Bitkilerin yerleştirilmesinde sıra arası mesafe 45 cm, sıra üzeri (bitkiler arası) mesafe ise 15 cm olarak belirlenmiş; bu mesafeler bitkilerin büyüme alanını maksimize etmek ve ışık, hava ve suya erişimlerini dengelemek amacıyla seçilmiştir. Ekim işlemleri, 5-6 cm derinliğe yerleştirilen tohumlarla manuel olarak yapılmış ve her bir parselin homojen büyüme koşulları sunması için toprak yapısı, eğim ve güneşlenme gibi faktörler göz önünde bulundurulmuştur. Açık alanda gerçekleştirilen bu düzenek, gerçek tarımsal üretim ortamını yansıtmaması açısından önemli olup, hem doğal stres faktörlerinin hem de görüntü işleme ve sensör tabanlı ölçüm sistemlerinin eş zamanlı çalışmasını mümkün kılmıştır.



Şekil 8. a) Parsel detayları ve kamera yerleşim düzeni b) açık tarla planı

Deneyin yürütüldüğü tarla toprağına ait fiziksel ve kimyasal özellikler, Ağrı İbrahim Çeçen Üniversitesi Merkezi Araştırma ve Uygulama Laboratuvarı tarafından yapılan analizler sonucunda belirlenmiştir. **Tablo 1**'de verilen analiz sonuçlarına göre, toprak bünyesi hem su ile doygunluk hem de hidrometre yöntemiyle değerlendirilmiş ve her iki yöntem sonucunda da "killi" olarak sınıflandırılmıştır. Toprak reaksiyonu (pH) değeri 8,03 olarak ölçülmüş ve bu sonuç, toprağın "kuvvetli alkali" özellik gösterdiğini ortaya koymuştur. Elektriksel iletkenlik (EC) değeri 0,23 olarak bulunmuş ve toprak "hafif tuzlu" sınıfına girmiştir. Kireç oranı %6,48 olup, bu değer "orta kireçli" bir toprak yapısını işaret etmektedir. Organik madde oranı ise %17,42 gibi oldukça yüksek bir değere sahiptir ve bu durum "organik madde çok fazla" olarak değerlendirilmiştir; bu da mikrobiyal aktivite ve besin maddesi döngüsü açısından oldukça elverişli bir ortam sunmaktadır. Bitkiye alınabilir fosfor miktarı 22,21 kg/da olup "orta seviyede", alınabilir potasyum miktarı ise 46,25 kg/da olarak "iyi" seviyede belirlenmiştir. Elde edilen bu veriler, deneme sahasının bitki gelişimi ve sulama deneyleri açısından verimli ve analizlere uygun bir altyapı sunduğunu göstermektedir.

Tablo 1. Toprak Analizi Sonuçları

Parametre	Birim	Analiz Sonucu	Değerlendirme
Bünye (Saturasyon)	%	83,4	Killi
Toprak Reaksiyonu (pH)	-	8,03	Kuvvetli Alkali
Toplam Tuz (EC)	%	0,23	Hafif Tuzlu
Kireç	%	6,48	Orta Kireçli
Organik Madde	%	17,42	Organik Madde Çok Fazla
Alınabilir Fosfor (P_2O_5)	kg/da	22,21	Orta Seviyede
Alınabilir Potasyum (K_2O)	kg/da	46,25	İyi
Bünye	-	87,32	Killi

Görüntü işleme çalışmasında kullanılacak veri setinde, bitkilerin suya bağlı olarak gösterdiği şekilsel farklılıkların ortaya konabilmesi amacıyla farklı sulama düzeylerinin uygulanması gerekmektedir. Bu kapsamda, sulama miktarları, bitkisel su tüketimini temsil eden ET_c değerinin belirli yüzdeleri esas alınarak belirlenmiştir. Literatürde sıklıkla karşılaşılan uygulamalarda sulama düzeylerinin %100-80-60 ET_c (Alegewe et al., 2023), %100-75-50-25-0 ET_c (Zelege & Nendel, 2024) ve %100-75-50-25 ET_c (Narendra Singh Chandel et al., 2024) oranlarında düzenlendiği görülmektedir. Bu doğrultuda, **Şekil 9**'da görüldüğü gibi deneysel çalışmamızda da literatürle uyumlu olacak şekilde, parsel bazında %100, %75, %50 ve %25 ET_c oranları kullanılmıştır.




Şekil 9. 100%, 75%, 50% ve 25% ET_c oranları ile sulanan bitki görselleri ve sarı kesikli çizgiler nemli bölge sınırlarının göstermektedir.

Araştırmada kullanılan sulama düzeylerinin belirlenmesinde çevrimiçi olarak erişilebilen SUET programı, farklı iklim bölgelerinde yetiştirilen tarımsal ürünler için su tüketimini bilimsel yöntemlerle hesaplamak üzere çalışmaktadır. SUET programı, uluslararası geçerliliğe sahip Penman-Monteith yöntemine (Hu et al., 2022; Nawandar & Satpute, 2019; Tunca & Köksal, 2022) dayanmaktadır ve hesaplamalarında deney lokasyonuna ait son 30 yıla ait uzun dönemli iklim verilerini kullanmaktadır. Bu özellik, programın mevsimsel

değişkenlikleri dikkate alarak daha gerçekçi ve yerel koşullara uygun tahminler sunmasını sağlamaktadır.

Çalışma kapsamında, SUET yazılımına **Şekil 10** ve **Şekil 11**' da görüldüğü üzere deney alanının konumu, toprak tipi, bitki türü (fasulye), ekim tarihi, bitki gelişim periyodu, yüzey örtüsü durumu ve sulama yöntemi (damla sulama) gibi çeşitli parametreler girilmiş; böylece sistem, bitkinin ihtiyaç duyduğu toplam su miktarını ve sulama zamanlamasını otomatik olarak hesaplamıştır.



Şekil 10. SUET programının kullanımı



İl	AĞRI
İstasyon	Ağrı
Bitki	fasulye(kuru)
Sulama Yöntemi	Damla
Sulama Randımanı (%)	85
Islatılan Alan Oranı (%)	60
Sulama Programlama Tekniği	Özel Sulama Aralığı

Mevsimlik ETc (mm)	550,41	Std Penman Monteith
Mevsimlik ETa (mm)	550,41	
Verim Kaybı (%)	0	
Su Kaybı (mm)	26,09	

Şekil 11. SUET sulama programı raporu

SUET programında kullanılan ve sulama ihtiyacını belirlemeye yönelik hesaplamaları denklem 1-4 ile verilmektedir.

$$ET_c = K_c \times ETo \quad (1)$$

$$T = ET_c \times \frac{Ps}{85} \quad (2)$$

$$dn = T - Pe \quad (3)$$

$$dt = \frac{dn}{Ea \times Ec} \quad (4)$$

Bu hesaplamalarda ET_c , belirli bir bitkinin gelişme döneminde ihtiyaç duyduğu toplam su tüketimini (mm) ifade eder. Bu değer, her bitki için farklı değer alan K_c katsayısı ETo (referans evapotranspirasyon) büyüklüklerinin çarpılması ile hesaplanır. ETo , standart koşullardaki çim örtüsünün evapotranspirasyon değerini temsil eder ve bölgedeki iklim verilerine bağlı olarak değişir. T ile ifade edilen düzeltilmiş su tüketim miktarı denklem 2’de verildiği gibi belirlenir. Burada 85 sabiti, ışık geçirgenliğini ifade eden ampirik bir değerdir ve bitkinin yüzey kaplama etkisini normalize etmek amacıyla kullanılmaktadır. Bitkinin net sulama suyu ihtiyacı (dn), bu şekilde elde edilen T büyüklüğünden etkili yağış miktarını ifade eden Re ’nin çıkarılması ile hesaplanır. Son olarak net sulama suyu ihtiyacının (dn), Su uygulama randımanı (Ea) ile su iletim randımanı (Ec) büyüklüklerinin çarpımlarına oranlayarak mm cinsinden ifade edilen sulama sistemine uygulanacak toplam su miktarı (dt) elde edilir. Ea ve Ec büyüklükleri, sulama sisteminde oluşabilecek su kayıplarını dikkate alarak tarlaya ulaşması gereken su miktarının belirlenmesi için kullanılır.

Yukarıda açıklanan hesaplamalar, yalnızca teorik su ihtiyacını değil, aynı zamanda uygulama sisteminin verimliliğini de içeren çok katmanlı bir değerlendirme sunmaktadır. Bu sayede, deney boyunca uygulanan su miktarları yalnızca bitkinin ihtiyacına değil, aynı zamanda kullanılan sulama altyapısının teknik kapasitesine göre de optimize edilmiştir. SUET sistemi aracılığıyla elde edilen bu bilimsel planlama sayesinde, farklı sulama düzeylerinin (%100, %75, %50, %25 ET_c) bitki morfolojisi üzerindeki etkileri karşılaştırmalı olarak değerlendirilmiş ve deneysel veriler için sağlam bir zemin oluşturulmuştur. Deney sisteminde her parsel için bir sezon boyunca uygulanan mm cinsinden toplam sulama suyu miktarları **Tablo 2’**de verilmiştir.


Tablo 2. Parsel Başına Toplam Sulama Suyu (dt; mm)

Yılı Gün Sayısı	Parsel No				Yılı Gün Sayısı	Parsel No			
	1	2	3	4		1	2	3	4
150	6,13	3,17	4,7	6,13	214	14,82	4	7,7	11,41
159	7,09	3,42	5,19	6,96	216	15,27	3,97	7,78	11,6
164	7,86	3,94	5,91	7,87	218	14,02	3,84	7,34	10,85
168	8,54	2,66	4,8	6,94	220	14,15	3,89	7,43	10,96
172	8,12	4,84	6,87	8,9	222	13,64	3,76	7,17	10,58
175	9,13	3,32	5,6	7,88	224	13,81	4,02	7,47	10,93
178	10,1	3,75	6,28	8,8	226	14,62	4,06	7,71	11,36
180	8,68	2,78	4,95	7,12	228	14,41	3,6	7,2	10,8
182	8,93	4,9	7,13	9,36	230	14,21	3,83	7,38	10,93
184	9,36	3,05	5,39	7,73	232	13,97	4,62	8,12	11,61
186	10,37	3,66	6,26	8,85	234	13,15	3,45	6,74	10,03
188	10,96	3,38	6,12	8,86	236	13,62	3,51	6,91	10,32
190	11,6	3,87	6,77	9,67	238	12,58	3,45	6,6	9,75
192	11,93	3,64	6,62	9,61	240	12,07	3,12	6,13	9,15
194	12,81	3,41	6,62	9,82	242	11,59	3,12	6,02	8,92
196	14,18	3,66	7,2	10,75	244	12,3	3,47	6,55	9,62
198	15,17	3,84	7,63	11,42	246	12,42	3,41	6,51	9,62
200	15,17	4,23	8,02	11,81	248	11,96	3,29	6,28	9,27
202	14,66	3,85	7,52	11,18	250	11,28	3,26	6,08	8,9
204	15,37	4,68	8,52	12,37	253	15,18	4,04	7,84	11,64
206	14,75	4,23	7,91	11,6	256	13,32	3,48	6,81	10,14
208	14,52	4,88	8,51	12,14	260	13,44	3,58	6,94	10,3
210	14,39	4,7	8,3	11,9	266	11,64	3,37	6,28	9,19
212	14,45	4,09	7,71	11,32					




Şekil 12. Damlamam sulama sistemi

Deney sisteminde kullanılan sulama yöntemi Şekil 12’de görüldüğü üzere damla sulama sistemi olarak tasarlanmıştır. Sistem her parsel için bir adet 5L depodan ve her sıra için bir adet su pompasından oluşmaktadır. Sulama sistemi ve ölçüm sistemleri için Proteus devre şeması Şekil 13’te verilen elektronik sistemler kullanılmıştır.



Şekil 13. Elektronik kart devre şeması

Oluşturulan devre şeması **Şekil 14**'te görüldüğü gibi PCB kart üzerine baskı devresi çıkartılmış olup **Tablo 3**'de verilen devre elemanlarının montajı yapılmıştır. Elektronik kartta **Tablo 4**'de özellikleri verilen ESP32 mikro işlemciden iki adet kullanılmıştır. Bunlardan biri sulama sistemini kontrol ederken diğeri sensörlerden gelen verileri toplayıp bulut sistemine aktarmaktadır. Kartta gerçek zamanı tutmak için bir adet RTC (DS3231) kullanılmıştır. Sensör girişleri için bağlantı noktaları konularak montaj kolaylaştırılmıştır. Devrenin girişinde yer alan DC-DC dönüştürücü (LM2596) 12V giriş sinyalinin 5V düşürerek karttaki elektronik devre elemanlarının beslenmesini sağlamıştır. Ayrıca iki adet LED uyarı amaçlı eklenmiştir ve sistemde oluşan hatalarda önceden tanınmış protokole göre flaşlanarak bilgi vermektedir. Sulama sisteminin kontrolünü sağlayan ESP32'nin EEPROM'una, dört farklı sulama oranına karşılık gelen gün sayıları ve su miktarları önceden kaydedilmiştir. Sistem, bu verilere göre otomatik olarak bitkilerin sulanmasını sağlamıştır.



Şekil 14. Elektronik kart sisteminin PCB üzerine uygulanması

Tablo 3. Elektronik Sistem Bileşenleri


Sistem Bileşeni	Model / Özellik
Toprak Nem Sensörü	Kapasitif Toprak Nem Sensörü
Sıcaklığı ve Nem Sensörü	AM2302
Sıcaklık Sensörü	ds18b20
RTC	DS3231
Voltaj Dönüştürücü	LM2596
Kamera	OV2640
Mikroişlemci	ESP32

Tablo 4. ESP32 Teknik Özellikleri

Özellik	Açıklama
Mikrodenetleyici	Tensilica Xtensa LX7 çift çekirdekli işlemci
Saat Hızı	240 MHz (maksimum)
Çalışma Gerilimi	3,0 – 3,6 V (tipik 3,3V)
Flash Bellek	4 MB / 8 MB
PSRAM	8 MB
RAM	512 KB SRAM
Wi-Fi	IEEE 802.11 b/g/n (2.4 GHz)
Bluetooth	Bluetooth 5.0 LE
Giriş/Çıkış Pinleri (GPIO)	44 adede kadar (modele bağlı olarak değişir)
ADC (Analog Giriş)	12-bit çözünürlük, çoklu kanal (yaklaşık 20 kanal)
DAC (Analog Çıkış)	2 kanal (8-bit çözünürlük)
UART / SPI / I2C / I2S	Çoklu haberleşme protokol desteği
USB Desteği	Yerleşik USB-OTG (ESP32-S3 modellerinde)
PWM	Tüm GPIO pinleri PWM çıkışı olarak yapılandırılabilir
Derin Uyku Modu Güç Tüketimi	< 10 µA

Görüntü toplama sisteminde, OV2640 model 2 MP (1600×1200@15fps) çözünürlüğe sahip kamera, ESP32 mikrodenetleyici ve güç giriş modülünden oluşan sistem **Şekil 15**'te görüldüğü gibi, su geçirmez ve arazi koşullarında çalışmaya uygun bir muhafaza içerisine yerleştirilmiştir. Bu bileşen, her bir bitkinin 45° ve 90° açılarla görüntüsünü kaydedecek şekilde konumlandırılmış ve hem saksı hem de topraklı dikimler için kullanılmıştır. Toplamda 8 kamera sistemi kurulmuş ve her biri ile düzenli olarak veri toplamıştır. Görüntü alma işlemleri, yaprakların güneş ışığından minimum düzeyde etkilenmesini sağlamak amacıyla

sabah 08:00–09:00 saatleri arasında gerçekleştirilmiştir. Kurulan sistemde, kameralar ve sulama sistemi ile entegre çalışan ESP32 mikrodnetleyiciler, IoT altyapısı kapsamında ortak bir ağı bağlanmış ve bir modem aracılığıyla internete veri aktarımı sağlanmıştır. Bu şekilde günlük olarak kaydedilen görseller, Firebase bulut sistemine toplanarak merkezi bir veri seti oluşturulmuştur. Firebase'in ücretsiz veri depolama hizmeti sunması, sistemin toplam maliyetini azaltmada önemli bir avantaj sağlamıştır. Ayrıca Firebase altyapısı, IoT sistemine bağlı tüm cihazların uzaktan güncellenmesine (Over The Air – OTA) olanak tanımış ve böylece cihazların bulut üzerinden kolayca kontrolü ve yönetimi mümkün hale gelmiştir.



Şekil 15. Sulama sisteminde kullanılan IoT tabanlı görüntü toplama bileşeni

IoT Ortamları için Veri Tabanı Teknolojileri


IoT sisteminde sulama günü ve sulama miktarı verileri mikroişlemci üzerine tutulduğu için IoT sisteminde kullanılan dosya kayıt sistemlerinin ön analizi gerçekleştirilmiştir. Bu analizler için iki analiz sistem oluşturulmuştur ve bu sistemlerden ilki olan veri “kaydetme” ve “arama” parametrelerinin incelenmesinde kullanılan D1 sistemi bir adet ESP32 mikroişlemci içermektedir. İkinci sistem olan D2 ise 2 adet DS18B20 sensörü, 1 adet DHT11 nem sensörü, DS3231 RTC sensörü ve ESP32 içermektedir.

Yapılan ön çalışmada D1 analiz sisteminde üç versiyon algoritma ayrı ayrı çalıştırılmıştır. Farklı algoritmaların uygulanma sebebi ESP32 kullanabilecek SPIFFS ve LittleFS olarak iki farklı Dosya Sisteminin (FS) bulunmasıdır. Çalışmamızda SQLite veri tabanının performans değerlendirmesi LittleFS+ SQLite ve SPIFFS + SQLite için ayrı ayrı incelenmiştir. Kıyaslama için de Google tarafından üretilen ve NoSQL tabanlı Firebase veri tabanı kullanılmıştır. C++ dilinde yazılan kodda 10 sensör için 10 ve 100 kayıttan oluşacak rasgele üretilmiş sıcaklık, nem ve zaman bilgisi incelenmiştir.

D2 analiz sistem ise IoT iletişim ağı kaynaklı problemlerden dolayı kayıtlardaki aksamaları ortaya koymak için oluşturulmuştur. Oluşturulan IoT ağında toplamda 10 adet cihaz bulunmaktadır ve sistem günde 144 adet veri olacak şekilde 6 ay boyunca Firebase veri tabanına sıcaklık, nem ve zaman verilerini kaydetmiştir.

Görüntü İşleme

Bitki görsellerinden öznitelik elde etmede, görüntü işleme sürecinin önemli bir adımdır. Bu çalışmada, segmentasyon ve poz tahmini yöntemleri kullanılarak görsellerden anlamlı öznitelikler elde edilmesi hedeflenmiştir. Bu amaç doğrultusunda, Ultralytics tarafından geliştirilen YOLO (You Only Look Once) model ailesi tercih edilmiştir. YOLO modelleri, gerçek zamanlı nesne algılama alanındaki üstün performansları sayesinde yaygın biçimde kullanılmaktadır. Bu model ailesinin gelişmiş bir üyesi olan YOLOv11 (Jocher & Qiu, 2024), ileri düzey sinir ağı mimarisi ve optimize edilmiş eğitim stratejileri sayesinde çeşitli karmaşık görsel görevlerde yüksek başarı sergilemiştir (X. Wang & Wang, 2023). Bu versiyonun daha da geliştirilmiş hali ve serinin en güncel sürümü olan YOLOv12 (Tian et al., 2025), nesne algılama teknolojisindeki son gelişmeleri yansıtarak çalışmamız için güçlü bir başlangıç noktası sunmaktadır (Wei et al., 2024). Tian et al. (2025) tarafından yapılan **Şekil 16**'da farklı algoritmaların performans karşılaştırmaları gösterilmiştir. Görüldüğü üzere önceki sürümlere kıyasla YOLOv12 modeli daha üstün mAP değerlerine ulaşmıştır. Gerçek zamanlı nesne algılama, segmentasyon ve poz tahmini gibi birçok uygulamayı desteklemesi sayesinde; nesneleri yönelimi, ölçeği ya da boyutu ne olursa olsun yüksek doğrulukla tanımlayabilmekte ve bu özelliğiyle özellikle tarım ve güvenlik gibi sektörlerde çok yönlü kullanım imkânı sunmaktadır (Sapkota et al., 2024). Tüm bu üstün nitelikleri nedeniyle, segmentasyon ve poz tahmini işlemlerinde YOLOv12 modeli tercih edilmiştir.



Şekil 16. YOLOv12 ‘nin diğer popüler yöntemlerle gecikme-doğruluk kıyaslaması (Tian et al., 2025)

YOLO modellerinin aşamaları tipik olarak ön işleme, öznitelik çıkarma, sınırlayıcı kutu tahmini ve son işlemeyi içerir. Ön işleme aşaması, görüntüler gibi girdi verilerinin sonraki işlemlere uygunluklarını artırmak için iyileştirilmesini içerir. Bu, verileri özellik çıkarmaya hazırlamak için yeniden boyutlandırma, normalleştirme gibi işlemleri içerebilir (Hou et al., 2023). Öznitelik çıkarma, modelin önceden işlenmiş verilerden ilgili özellikleri tanımladığı ve çıkardığı çok önemli bir aşamadır. Bu aşama genellikle girdi verileri içindeki karmaşık desenleri ve özellikleri yakalamak için CNN'ler kullanımını içerir ve modelin ilgilenilen nesneleri ayırt etmesini sağlar (Zhong et al., 2023). Özellik çıkarma sonrasında model, sınırlayıcı kutu tahmini aşamasına geçer. Bu aşamada, algılanan nesnelerin etrafında sınırlayıcı kutular oluşturulur ve bunlarla ilişkilendirilmiş güven skorları üretilir. Bu aşama, nesnelerin konumunu ve varlığını belirlemede önemlidir ve modelin nesne tespit yeteneklerine katkı sağlar (Hou et al., 2023). Son işleme, tahmin edilen sınırlayıcı kutuların ve ilişkilendirilmiş nesne tespitlerinin iyileştirilmesi ve doğrulanması aşamasıdır. Bu aşama genellikle, algılanan nesneleri filtrelemek ve birleştirmek için maksimum olmayan bastırma ve diğer teknikleri içerir, böylece doğru ve güvenilir sonuçlar elde edilir (Song et al., 2022). YOLO modelinin aşamaları, etkili ve doğru nesne tespiti sağlayarak çeşitli uygulamalara uygun hale getirir, bu da gerçek zamanlı tespit, endüstriyel inceleme ve IoT entegrasyonu gibi alanlarda kullanılabilir (Hou et al., 2023; Pestana et al., 2021; Song et al., 2022).

Bu çalışmada kullanılan YOLOv12 modeli, CNN tabanlı nesne tespit sistemlerinin düşük gecikme süresi avantajlarını koruyarak, dikkat mekanizmalarının modelleme gücünü entegre eden yenilikçi bir yapı sunmaktadır. YOLO ailesinin en son sürümü olan YOLOv12, nesne tespitinde daha yüksek doğruluk elde etmek amacıyla, hesaplama verimliliğini ön planda tutan yeni bir mimari ile geliştirilmiştir. Model, özellikle alan dikkat mekanizması (Area Attention Module - A2) ve artık verimli katman birleştirme ağları (Residual Efficient Layer Aggregation Networks - R-ELAN) gibi yenilikçi yaklaşımlar kullanılarak tasarlanmıştır.

YOLOv12 mimarisi

YOLOv12 **Tablo 5**'te görüldüğü üzere YOLO versiyonlarının en son modelidir ve en gelişmiş mimariye sahiptir. YOLO çerçevesinin başarısı, tarihsel olarak sınırlayıcı kutu regresyonu ile nesne sınıflandırmasını aynı anda gerçekleştirebilen bütünleşik bir mimariye dayanmaktadır. YOLOv12, bu temel ilkeleri daha da ileri taşıyarak, daha yüksek doğruluk, daha düşük gecikme süresi ve artırılmış uyarlanabilirlik için özel olarak tasarlanmış yeni yapısal yenilikleri entegre etmektedir. YOLOv12'nin tasarımı üç ana bileşen altında incelenebilir: öznitelikleri çok ölçekli çıkaran ve işleyen “omurga” (backbone); bu özellikleri birleştirip iyileştiren “boyun” (neck); ve son tahminleri üreten “kafa” (head) bileşeni.

Tablo 5. YOLO Modellerinin Ayırıcı Özellikleri

Model	Yıl	Özelliği
YOLO	2015	Tek aşamalı nesne tespit modeli
YOLOv2	2016	Çok ölçekli eğitim, boyut kümeleme
YOLOv3	2018	SPP bloğu, Darknet-53 omurgası
YOLOv4	2020	Mish aktivasyonu, CSPDarknet-53 omurgası
YOLOv5	2020	Anchor-free (çapasız) tespit, SWISH aktivasyonu, PANet
YOLOv6	2022	Öz-dikkat (self-attention), anchor-free nesne tespiti
YOLOv7	2022	Transformerlar, E-ELAN yeniden yapılandırması
YOLOv8	2023	GAN'ler, anchor-free tespit
YOLOv9	2024	PGI ve GELAN
YOLOv10	2024	NMS'siz eğitim için tutarlı çift atama yöntemi
YOLOv11	2024	Genişletilmiş yetenekler, artırılmış verimlilik
YOLOv12	2025	Gelişmiş dikkat merkezli tasarım (FlashAttention, R-ELAN), 7×7 ayrılabilir evrişimler, geliştirilmiş performans


Omurga (backbone) modülü

YOLOv12'nin omurgası, ham görüntü verilerini çok ölçekli özellik haritalarına dönüştürerek, sonraki nesne tespiti görevleri için temel temsilleri sağlayan kritik bir bileşendir. Bu yapının merkezinde yer alan Artık Etkin Katman Birleştirme Ağı (Residual Efficient Layer Aggregation Network - R-ELAN), derin konvolüsyon katmanlarını dikkatle yerleştirilmiş artık (residual) bağlantılarla birleştirmektedir. Bu tasarım, gradyan darboğazlarını azaltmakta ve özelliklerin yeniden kullanımını artırarak, modelin farklı boyut ve şekillerdeki nesnelere ait karmaşık ayrıntıları daha etkili bir şekilde yakalayabilme kapasitesini güçlendirmektedir.

- Bu yapı, katmanlar arasında bilgi akışını güçlendiren ELAN mimarisinin geliştirilmiş bir versiyonudur ve artık bağlantılar (residual connections) eklenerek modelin daha derin özellikleri öğrenmesini sağlar.
- Özellikle büyük modellerde (örneğin YOLOv12-L ve YOLOv12-X), bu artık bağlantılar sayesinde modelin eğitim süreci daha dengeli ilerlerken, düşük bir ölçeklendirme katsayısı (örneğin 0,01) kullanılarak bu bağlantıların modeli olumsuz etkilemesi önlenir.
- Bu sayede hem parametre sayısı ve işlem yükünü düşük tutarken hem de yüksek doğruluk sunmaktadır. Küçük modellerde bu bağlantıların etkisi sınırlı olsa da, büyük modellerde modelin kararlı bir şekilde öğrenmesi için oldukça kritik bir rol oynar.
- Gerçek zamanlı uygulamalarda hızlı ve doğru sonuçlar elde edilmesini kolaylaştıran bu yapı, YOLOv12'nin başarısını artıran temel bileşenlerden biridir.

Boyun (Neck) modülü

YOLOv12 mimarisinde omurga ile kafa bileşeni arasında bir köprü işlevi gören boyun (neck) yapısı, çok ölçekli özellikleri birleştirme ve iyileştirme görevini üstlenmektedir. Bu yapının en dikkat çeken yeniliklerinden biri, FlashAttention ile hızlandırılan alan temelli dikkat (area attention) mekanizmasıdır. Diğer tür dikkat mekanizmaları ile karşılaştırmalı olarak **Şekil 17**'de gösterilen bu mekanizma, karmaşık sahnelerde modelin kritik bölgelere odaklanma yetisini artırmaktadır. Öznitelik haritalarının alanlara ayrılması ve hızlı dikkat mekanizmalarının uygulanması yoluyla, YOLOv12 bellek transferlerini ve hesaplama yükünü azaltmakta; böylece daha yüksek çözünürlüklü girişlerde dahi gerçek zamanlı çıkarım yapılmasını mümkün kılmaktadır.



Şekil 17. Dikkat mekanizmaları. a) çapraz dikkat, b) pencere dikkat, c) eksenel dikkat, d) alan dikkat mekanizması

Bu dikkat mekanizması kapsamı, bağlamı, hesaplamama maliyeti ve esneklik yönüyle diğer dikkat mekanizmalarıyla karşılaştırılmaları **Tablo 6**'da verilmiştir.

Tablo 6. Dikkat Mekanizmalarının Karşılaştırılması

Mekanizma	Kapsama Alanı	Bağlam Türü	Hesaplama Maliyeti	Esneklik
Çapraz dikkat	Sadece satır ve sütun	Yarı-global	Orta	Düşük
Pencere dikkat	Lokal pencere	Lokal	Düşük	Orta
Eksenel dikkat	Sadece bir eksen	Yarı-global	Düşük	Orta
Alana dikkat	Geniş yatay/dikey alan	Geniş bağlam	Düşük-Orta	Yüksek


Kafa (Head) modülü

YOLOv12'nin baş (head) bileşeni, boyun (neck) yapısından gelen iyileştirilmiş öznitelik haritalarını son tahminlere dönüştürerek sınırlayıcı kutu (bounding box) koordinatları ve sınıflandırma puanlarını üretir. Bu aşamadaki temel iyileştirmeler arasında, optimize edilmiş çok ölçekli tespit yolları ile yerleştirme ve sınıflandırma hedefleri arasında daha iyi denge kuran özel kayıp fonksiyonları yer almaktadır. Bu tür yapısal geliştirmeler, YOLOv12'nin gerçek zamanlı uygulamalardaki performansını daha da artırmaktadır.

YOLOv12, yenilikçi omurga unsurlarını, gelişmiş dikkat mekanizmalarını ve hassaslaştırılmış tahmin modüllerini bütünleştirerek önemli bir yapısal evrim gerçekleştirmiştir. Bu bileşenlerin birlikte çalışması, nesne tespitinde hem hız hem de doğruluk açısından yeni standartlar belirlerken, aynı zamanda örnek segmentasyonu gibi daha özel görev alanlarına da sorunsuz bir şekilde uyarlanabilmesine olanak tanımaktadır.

YOLOv12'nin mimari tasarımı önceki yapı korunarak, bu temel üzerine bazı bileşenleri entegre edilerek geliştirilmiştir. Bu anlamda N, S, M, L ve X olarak ifade edilen beş farklı ölçek üzerinden optimize edilerek model geliştirilmiş ve farklı hesaplama gereksinimlerine sahip uygulamalar için geniş bir kullanım yelpazesi sunulmuştur. **Şekil**

18’de YOLOv12 mimarisinin ve bu mimaride yer alan ölçek parametrelerinin kullanımı gösterilmiştir. Mimaride önceki versiyonda kullanılan C3k2 katmanını da yer alırken, bahsedilen yenilikler A2C2f katmanında uygulanmıştır.



Şekil 18. YOLOv12 mimarisi

Sonuç olarak, YOLOv12, nesne tespitinde dikkat mekanizmalarını etkin bir şekilde kullanarak, geleneksel evrişimli modellerin hız avantajlarını koruyan bir mimari ile geliştirilmiştir. Modelin sunduğu alan dikkat mekanizması, artık katman birleştirme ağı ve FlashAttention optimizasyonları, YOLO ailesinin önceki sürümlerine kıyasla daha yüksek doğruluk, düşük hesaplama maliyeti ve artırılmış işlem verimliliği sağlamaktadır. Bu özellikleriyle YOLOv12, özellikle gerçek zamanlı nesne tespiti gerektiren uygulamalar için güçlü bir çözüm sunmakta olup, bilimsel araştırmalar ve endüstriyel kullanımlar için geniş bir kullanım potansiyeline sahiptir.

YOLO Tabanlı Segmentasyon ve Poz Eğitimi



Segmentasyon ve poz tahmini görevleri için YOLOv12 model ailesinin alt sürümleri (n, s, m, l ve x) arasından en yüksek başarıma sahip olan YOLOv12x modeli tercih edilmiştir. Bu modelin eğitilebilmesi için, deney sisteminden elde edilen görsellerin uygun biçimde etiketlenmesi gerekmektedir. Bu doğrultuda, modeli eğitmek için, deneysel sistemdeki kameralar tarafından toplanan ve Firebase veri tabanında saklanan 1360 görüntünün, Anylabeling programı ile segmentasyon ve poz tahmini için ayrı ayrı etiketlenmesi gerçekleştirilmiştir. Görüntüler önce Anylabeling programı ile segmentasyon için ayrı ve poz tahmini için ayrı olacak şekilde elde etiketlenmiştir ve 2 ayrı etiket seti oluşturulmuştur. **Tablo 7**'de bu segmentasyon ve poz tahmini için gerçekleştirilen etiketlendirme işlemine ait detaylar sunulmuştur. Bu etiketli veri setlerinin %80'i eğitim, %10'nu doğrulama ve %10'nu da test olacak şekilde rasgele bölünmüştür ve YOLOv12-Seg ve YOLOv12-Pose olarak isimlendirilen segmentasyon ve poz tahmin modelleri Google Colab platformu üzerinde eğitilmiştir. Eğitim süreci; başlangıç ve son öğrenme oranı 0,01, momentum 0,937, ağırlık azalması (weight decay) 0,0005, görüntü boyutu 640x640 piksel, toplam 200 epoch ve 16 batch olacak şekilde yapılandırılmıştır.

Tablo 7. Etiketlenen Nesne Sayıları

Nesne İsmi	Görev	Etiketli Nesne Sayısı
Bitki	Segmentasyon	1955
Meyve	Segmentasyon	707
Yaprak	Segmentasyon	25792
Tahta	Segmentasyon	1328
Sap-Alt	Poz	1423
Sap-Üst	Poz	1423
Yaprak-Orta	Poz	1423
Yaprak-Sağ	Poz	1423
Yaprak-Sol	Poz	1423
Yaprak-Uç	Poz	1423


Öznitelikleri Kullanarak Bitki Morfolojik Özelliklerinin Çıkarılması

YOLOv12 modeli eğitildikten sonra, veri setindeki görsellerden öznitelik çıkarımı yapmak amacıyla model kullanılarak segmentasyon ve poz tahmini işlemleri gerçekleştirilmiştir. Bu tahmin çıktıları **Şekil 19**'da görüldüğü üzere bağımsız değişkenlerin hesaplanması için Python ortamında yazılan algoritma kullanılmıştır. Burada segmente edilen yaprak, meyve ve bitki maske bilgileri kullanılarak bir sonraki katman için girdiler oluşturulmuştur. Segmentasyon maskelerinin piksel adetleri resimlerde bulunan referans tahta nesnesinin piksel adetine göre gerçek alan bilgisine dönüştürülmüştür. Böylece Yaprak Yüzey Alanı (Sy), Meyve Yüzey Alanı (Sm) ve Bitki Alanı (Sb) bağımsız değişkenleri hesaplanmıştır.




Şekil 19. Bitki su ihtiyacı tahmininde takip edilen işlem adımları

Şekil 20a'da, yaprak eğilme açısının belirlenmesi için kullanılan 3 referans noktası gösterilmiştir. Üç referans nokta sarı, mavi ve kırmızı renklerle gösterilmiştir. Bunlardan sarı nokta yaprak sapının bitki gövdesine bağlandığı yerde, mavi nokta yaprak ile sapın birleşim yerde ve kırmızı nokta yaprak ucundadır. Bu üç referans noktasına dayalı olarak çalışmada ayrı iki vektör oluşturulmuştur. Bunlardan sarı-mavi noktaları birleştiren vektör yaprağın yatay doğrultusunu belirlerken, mavi-kırmızı noktaları birleştiren vektör yaprağın ana damarı boyunca uzanan eksenini belirler. Bu iki vektör arasındaki açı, $\hat{A}$ sembolü ile gösterilip yaprak eğimi olarak tanımlanır. **Şekil 20a**'da $\hat{A}$ açısının 180 dereceden yakın olduğundan su stresinin olmadığı, **Şekil 20b**'de ise $\hat{A}$ açısının 180 dereceden küçük olup su stresinin olduğu şematik görseller sunulmuştur. Yaprak eğimi **Şekil 20**'ye göre de ifade edilen bitki su ihtiyacıyla ilişkilidir. Transpirasyon hızının artması ve su alımındaki dengesizlik gibi faktörler, yaprak hücrelerinde turgor basıncının düşmesine neden olur. Bunun sonucu olarak, yapraklar dik konumlarını kaybederek aşağı doğru sarkar.



Şekil 20. Şematik temsili yaprak görselinde referans noktaları a) $\hat{A}$ açının 180 dereceye yakın olması, su stresinin olmadığını gösterir. b) $\hat{A}$ açının 180 dereceden düşük olması, su stresinin varlığını gösterir.


Şekil 21'de, doğal ortamda çekilmiş yaprak görselleri verilmiştir. **Şekil 21a**'da, yaprak eğiminin ihmal edilebilir düzeyde olduğu bir örnek sunulmuştur. Bu durumda $\hat{A}$ açısı 180 dereceye oldukça yakındır. Bu durum, yaprağın fizyolojik olarak düz durduğunu ve bitkinin yeterli suya erişimi olduğunu, dolayısıyla su stresi yaşamadığını göstermektedir (Briglia et al., 2020). Buna karşılık, **Şekil 21b**'deki yaprak görüntüsünde belirgin bir eğilme gözlenmektedir. Yaprak ucunun aşağıya doğru sarkması, mavi ve sarı noktalar arası referans doğrusu ile yaprak ana damarı arasındaki açının ($\hat{A}$) 180 dereceden sapmasına neden olmaktadır. Bu açı azalması, literatürde bitkinin su stresine girdiği durumlarda rapor edilen bir fizyolojik tepkiyi yansıtır (Anjum et al., 2012; Chen et al., 2019; Zhang et al., 2017) (Briglia et al., 2020).



Şekil 21. Gerçek yaprak görselinde poz noktaları a) $\hat{A}$ açısına göre su stresinin olmadığı yaprak görseli, b) $\hat{A}$ açısına göre su stresinin olduğu yaprak görseli.

Çalışmada $\hat{A}$ açısı belirlendikten sonra yaprağın duruşuna göre su stresinin olup olmadığına karar vermek için yaprağın sap noktasına göre uç noktasının konumunu analiz edilerek yaprak pozisyon bilgisi üretilmiştir. Bu işlem için **Şekil 22**'de verilen koordinat sistemine göre yaprağın su stresinden dolayı uç noktasının aşağı yönde eğilme durumu belirlenmiştir. Burada yaprağın sağa dönük olma durumu $+X$, sola dönük olması $-X$ ile yaprak uç noktasının yaprak sapına göre yukarda olma durumu $+Y$ ve aşağıda olma durumu $-Y$ ile gösterilmiştir. Su stresinin varlığının tespitinde yaprağın uç noktasının aşağı yönde

olması beklendiğinden bu bilgiyi ifade edecek görseller -Y yönünde (III ve IV bölgesi) olacaktır. Böylece sıcaklık, rüzgar, hastalık ve fiziki bozukluklar gibi nedenlerden dolayı yaprakta oluşabilecek $\hat{A}$ açısı değerlerinin su stresi tahminini etkilemesinin önüne geçilmiştir.



Şekil 22. Su stresi varlığının tespitinde kullanılan referans nokta işaretlerine göre yaprakların farklı konumları

Tahmin Modeli ve Performans Değerlendirmesi

Bitkinin su ihtiyacının belirlenmesine yönelik olarak, **Şekil 19**'da gösterildiği gibi görüntü işleme adımları sonucunda elde edilen fiziksel özellikler ile K_c ve ET_c arasındaki ilişkiyi analiz etmek amacıyla YSA modeli kullanılmıştır (Tong et al., 2023; Tunalı et al., 2023). Model mimarisi dört gizli katmandan oluşmakta olup, bu katmanlarda sırasıyla 256, 128, 64 ve 32 nöron yer almaktadır. Aşırı öğrenmeyi (overfitting) önlemek amacıyla dropout oranı %20 olarak belirlenmiş ve her bir katmanda doğrusal olmayan öğrenme sürecini desteklemek üzere ReLU (Rectified Linear Unit) aktivasyon fonksiyonu kullanılmıştır. Modelin performansını değerlendirmek amacıyla kök ortalama karesel hata (RMSE), ortalama mutlak yüzde hata (MAPE) ve determinasyon katsayısı (R^2) gibi performans metrikleri hesaplanmıştır. Model eğitimi ve validasyonu, rastgele ayrılmış eğitim ve test veri setleri üzerinde gerçekleştirilmiştir. Böylece tüm veri setinin %80'ni eğitim %20'si ise test amaçlı kullanılmıştır. Elde edilen sonuçlar literatürde yer alan mevcut çalışmalarla kıyaslayarak K_c ve ET_c tahinleri doğrulanmıştır. Bu yöntemsel yaklaşım, sensörsüz tahmin uygulamalarında görsel verilerin kullanım potansiyelini ortaya koymak amacıyla uygulanmıştır.

YSA modelinin tahmin başarımı için kullanılan RMSE, MAPE ve R^2 metrikleri denklem 5-7 de tanımlanmıştır.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (5)$$

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (6)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (7)$$

Burada y_i modelin gerçek değerini, $\hat{y}_i$ modelin tahmin ettiği değeri ve $\bar{y}$ gerçek değerlerin ortalamasını göstermektedir.

Öte yandan, YOLOv12 modelinin doğruluğunu ölçmek için literatürde sıkça başvurulan 4 temel metrik olan, keskinlik (P), duyarlılık (R), F1 ve mAP kullanılmıştır (Lou et al., 2023; Ma & Pang, 2023; Soeb et al., 2023). Bu metrikler denklem 8-12 ile tanımlanmıştır.

$$P = \frac{TP}{TP + FP} \quad (8)$$

$$R = \frac{TP}{TP + FN} \quad (9)$$

$$AP = \int_0^1 P(R) dR \quad (10)$$

$$mAP = \frac{\sum_{i=1}^N AP_i}{N} \quad (11)$$

$$F1 = 2 \left(\frac{P * R}{P + R} \right) \quad (12)$$

Burada TP doğru tahmin edilen, FP yanlış tahmin edilen pozitif örnekleri ifade ederken, TN doğru, FN yanlış tahmin edilen negatif örnekleri ifade etmektedir. Burada P, modelin tespit ettiği nesneler arasında doğru tanımlananların oranını, R modelin pozitif örnekleri ne oranda başarılı ile tespit edildiğini ölçmektedir. Ortalama Hassasiyet (AP), P ve R değişimine bağlı olarak integral alınarak hesaplanmaktadır Ayrıca mAP@50 hesaplanırken, farklı nesne sınıflarına ait hassasiyet değerlerinin ortalaması alınmaktadır. Bu metrik, model

tarafından tahmin edilen sınırlayıcı kutuların, en az %50 oranında gerek sınır kutularıyla rtüşmesini saėlayarak modelin genel doėruluėunu deėerlendirmektedir. F1 skoru ise, keskinlik ve duyarlılık deėerlerinin harmonik ortalamasını alarak hem yanlış pozitif hem yanlış negatif hataları dikkate alan dengeli bir performans lütü sunmaktadır.




ARAŞTIRMA BULGULARI VE TARTIŞMA

Tez çalışması, tarımsal su yönetiminde bitki bazlı görüntü işleme yöntemlerinin etkinliğini değerlendirmek amacıyla gerçekleştirilmiştir. ETc tahmin modelleri genellikle meteorolojik verilere veya sensör tabanlı sistemlere dayanırken, bu çalışmada düşük maliyetli ve erişilebilir bir alternatif olarak görüntü işleme ve yapay zeka destekli bir yaklaşım benimsenmiştir. Çalışmanın temel amacı, fasulye bitkisi için su ihtiyacını belirlemek üzere bitki morfolojisine dayalı bağımsız değişkenler kullanarak Kc ve su stresinin etkisini de ortaya koyarak ETc tahmin eden bir model geliştirmektir. Bu kapsamda, YOLO tabanlı segmentasyon ve poz tahmini yöntemleri ile Sy, Sm, Sb ve $\hat{A}$ değerleri hesaplanmış ve bu değişkenlerin bitkinin su tüketimi ile olan ilişkisi analiz edilmiştir. YSA ile modellenen sistem, görsel verileri kullanarak Kc ve ETc değerlerini tahmin etmiş ve elde edilen sonuçlar hem ölçülen meteorolojik verilerle elde edilen sonuçlar hem de literatürdeki çalışmalar ile karşılaştırılmıştır.


IoT Veri Tabanı Analiz Sonuçları

IoT sistemi için kullanılan üç veri tabanı (LittleFS+ SQLite, SPIFFS + SQLite ve Firebase) için analizler yapılmış ve bu işlemler iki IoT sistemi test edilmiştir. D1 sistemi ile yapılan kaydetme işlemi sonucunda elde edilen performans göstergeleri **Şekil 23**'de verilmiştir. Elde edilen veriler kaydetme işlemi için LittleFS sistemine kurulan SQLite veri tabanına (LittleFS+ SQLite) 100 veriyi 109961 μ s, SPIFFS sistemine kurulan SQLite veri tabanına (SPIFFS + SQLite) 100 veriyi 56031 μ s ve Firebase üzerine kaydedilen 100 veri için 23971 μ s zaman geçtiği görülmüştür. Benzer şekilde bu süreler 1000 veri için LittleFS+ SQLite 324706 μ s, SPIFFS + SQLite 138964 μ s olarak belirlenmiştir. Bu analize Firebase dahil edilmeme nedeni saatlik 100 veri kaydetme sınırının (ücretsiz kullanım için) olmasıdır. Bu sonuçlara göre kaydetme işlemi için NoSQL veri tabanı olan Firebase SQL veri tabanına göre çok daha hızlıdır. Ayrıca SPIFFS' nin LittleFS' den daha hızlı olduğu sonucuna varılmıştır.



Şekil 23. Kaydetme işlemlerinde oluşan gecikmeler

D1 sistemi ile yapılan ikinci analiz ise arama işlemidir. Bu işlem sonucunda elde edilen sonuçlar **Şekil 24**'te verilmiştir. Yapılan 100 verinin bulunduğu veri setinden yapılan arama işleminde LittleFS+ SQLite 165142 μ s, SPIFFS + SQLite 78951 μ s ve Firebase 419907 μ s zaman gecikme gözlemlenmiştir. Bu analizde Firebase veri tabanından “GET” işlemi gerçekleştirilmiştir. 1000 veri için LittleFS+ SQLite 791866 μ s, SPIFFS + SQLite 783602 μ s gecikme olduğu tespit edilmiştir. Yapılan kıyaslamada çok verinin olduğu arama işlemlerinde LittleFS ve SPIFFS sistemlerinde yakın sürede işlem yapılmış olsa da düşük veri setlerinde SPIFFS’in daha hızlı olduğu görülmüştür. Ayrıca bulut tabanlı sistemin lokal sistemlere göre veri getirmede çok daha fazla zaman harcadığı görülmektedir. Bunun muhtemel sebepleri bulut sistemlerinin güvenlik önlemleri içermesi ve internet hızının gecikme süresini etkilemesi ile açıklanabilir.



Şekil 24. Arama işlemlerinde oluşan gecikmeler

D1 sistemi ile LittleFS+ SQLite ile SPIFFS + SQLite hatasız kaç veriyi kaydedileceği incelenmiştir. SPIFFS + SQLite ortalama 2000 veri kaydından sonra yanıt vermezken LittleFS+ SQLite 10000 veriye kadar sorunsuz çalışmıştır. Sistem maksimum 10000 veri için kurulduğundan LittleFS+ SQLite bu sınır 10000 veriden daha fazladır.

Firebase bulut tabanlı olduğundan benzer bir analiz yürütebilmek için sistem D2 kurulanmıştır. D2 sistemi ile Firebase veri kayıpları analizi yapılmış ve 259200 veri kaydında %2,46 oranında bir veri kaybının söz konusu olduğu tespit edilmiştir. Bu veri kaybı IoT sisteminde oluşan iletişim ve internet kesintileri ile açıklanabilir bir seviye olduğu düşünülmektedir. Tüm bu veriler **Tablo 8**'de bir arada sunulmuştur.


Tablo 8. İşlemlere Göre Gecikme Süreleri

Veri Tabanı	Veri Sayısı	İşlem Türü	
		Kaydetme (µs)	Arama (µs)
LittleFS+ SQLite	100	109961	165142
	1000	324706	791866
SPIFFS + SQLite	100	56031	78951
	1000	138964	783602
Firestore	100	23971	419907

Sonuç olarak, IoT uygulamalarında sıklıkla kullanılan SQL ve NoSQL veri tabanı sistemlerinin kapsamlı bir karşılaştırması yapılarak, IoT verilerinin işlenmesinde iki veri tabanı türü arasındaki önemli performans farklılıkları ortaya konulmuştur. Yürütülen çalışmalar, bir NoSQL veritabanı olan Firestore'in hem LittleFS hem de SPIFFS dosya sistemleri üzerinde çalışan SQLite'a kıyasla kaydetme işlemlerinde önemli hız avantajları gösterdiği tespit edilmiştir. Bu durum, hızlı veri girişinin kritik olduğu ve sistem kısıtlamalarının izin verdiği uygulamalar için Firestore'in daha verimli bir seçenek sunduğunu göstermektedir. Buna karşılık, arama işlemleri, SPIFFS üzerindeki SQLite'ın özellikle daha küçük veri kümelerinde LittleFS' ye göre daha verimli performans gösterdiğini ortaya koymaktadır. Bu durum, sık veri transferinin gerekli olduğu sistemler için SPIFFS üzerinde SQLite'ın daha iyi performans sunabileceğini göstermektedir. Buna ek olarak, SPIFFS + SQLite sistemleri LittleFS + SQLite'a kıyasla daha düşük veri hacminde yanıt vermez hale gelmekte, bu da LittleFS'in daha büyük veri tabanları gerektiren uygulamalar için daha uygun olabileceği görülmüştür. Bu sonuçlar doğrultusunda tez çalışmasında sulama verilerinin internetten bağımsız çalışabilir olması gerektiğinde SPIFFS + SQLite sisteminde kaydedilmiş, YZ eğitimlerinde kullanılacak sensör verileri ve görseller ise Firestore sistemine kaydedilmiştir.

Segmentasyon Eğitim Sonuçları


YOLOv12 modeli için, fasulye bitkisinin yaprak (leaf), fasulye (bean) ve bitki (plant) olmak üzere üç temel bileşeninin segmentasyon eğitimi yapılmıştır. **Şekil 25'**te sunulan YOLOv12 tabanlı segmentasyon eğitim metrikleri incelendiğinde, modelin eğitim süreci boyunca kayıpların düzenli olarak azaldığı ve doğruluk ölçütlerinde anlamlı bir iyileşme sağlandığı görülmektedir. Özellikle kayıp değerlerinde eğitimin başından itibaren istikrarlı bir azalma gözlemlenmiştir.




Şekil 25. YOLOv12x-Seg modelinin eğitim metrikleri

Model performansını değerlendirmek amacıyla, duyarlılık (recall), F1 skoru, keskinlik (precision) ve keskinlik-duyarlılık (precision-recall) ilişkileri sınırlayıcı kutu için **Şekil 26**'da ve maske için **Şekil 27**'da gösterilmektedir. **Şekil 26a**'da verilen keskinlik-güven eğrisinde, güven değeri arttıkça keskinlik değerinin yükseldiği görülmektedir; bu durum, modelin yalnızca yüksek güven skoru taşıyan tahminleri değerlendirdiğinde daha isabetli sonuçlar verdiğini göstermektedir. Yine de orta seviye güven aralıklarında “yaprak” ve “fasulye” sınıflarında hassasiyetin, “bitki” sınıfına göre bir miktar daha düşük olduğu belirlenmiştir. **Şekil 26b**'da verilen duyarlılık-güven eğrisi incelendiğinde, tüm sınıflarda genel duyarlılık değeri 0,91 olarak belirlenmiş ve modelin düşük güven seviyelerinde yüksek duyarlılık performansı sergilediği, ancak güven seviyesi arttıkça duyarlılık oranının azaldığı gözlemlenmiştir. Özellikle “bitki” sınıfında diğer sınıflara kıyasla daha yüksek bir duyarlılık oranı elde edilmiştir. **Şekil 26c**'de verilen F1 skorunda özellikle “yaprak” ve “bitki” sınıflarında keskinlik ve duyarlılığın birlikte yüksek olması, bu sınıflarda güçlü bir F1 skoru elde edildiğini göstermekte, “fasulye” sınıfında ise keskinliğin yüksek ancak duyarlılığın

görece daha düşük olması nedeniyle F1 skorunun sınırlı bir artışla yükseldiği anlaşılmaktadır. Tüm sınıflar için 0,482 güven değerinde %87 F1 skoru ile elde edilmiştir. Bu değer, model için optimum eşik noktası olarak değerlendirilebilir. Son olarak, **Şekil 26d**'de verilen keskinlik-duyarlılık eğrisi , modelin genel performansını özetlemekte olup, tüm sınıflar için hesaplanan ortalama doğruluk (mAP@0,5) değeri %89,1 olarak belirlenmiştir. Bu dört eğri birlikte değerlendirildiğinde, modelin özellikle "yaprak" sınıfında yüksek duyarlılık ve keskinlik değerlerine ulaşarak diğer sınıflara kıyasla daha başarılı bir performans sergilediği söylenebilmektedir.



Şekil 26. YOLOv12x-Seg modelinin sınırlayıcı kutu için performans sonuçları, a) keskinlik - güven grafiği, b) duyarlılık - güven grafiği, c) F1 - güven grafiği, d) keskinlik - duyarlılık grafiği.



Şekil 27. YOLOv12x-Seg modelinin maske için performans sonuçları, a) keskinlik - güven grafiği, b) duyarlılık - güven grafiği, c) F1- güven grafiği, d) keskinlik - duyarlılık grafiği.

Tablo 9'da YOLOv12-Seg modeli için sınırlayıcı kutu performans sonuçları verilirken, **Tablo 10**'da maske için verilmiştir.

Tablo 9. YOLOv12x-Seg Modelinin Sınırlayıcı Kutu Performans Sonuçları


Nesne Adı	Keskinlik	Duyarlılık	mAP@0,5
Tümü	0,934	0,816	0,891
Yaprak	0,926	0,835	0,923
Fasulye	0,942	0,784	0,869
Bitki	0,934	0,829	0,880

Tablo 10. YOLOv12x-Seg Modelinin Maske İçin Performans Sonuçları

Nesne Adı	Keskinlik	Duyarlılık	mAP@0,5
Tümü	0,835	0,726	0,749
Yaprak	0,871	0,778	0,835
Fasulye	0,870	0,722	0,767
Bitki	0,765	0,678	0,645


Poz Eğitim Sonuçları

Şekil 28’de sunulan YOLO tabanlı poz eğitim metrikleri incelendiğinde, modelin eğitim süreci boyunca kayıpların düzenli olarak azaldığı ve doğruluk ölçütlerinde anlamlı bir iyileşme sağlandığı görülmektedir. Özellikle kayıp değerlerinde eğitimin başından itibaren istikrarlı bir azalma gözlemlenmiştir.

**Şekil 28.** YOLOv12x-Pose modelinin eğitim metrikleri

Modelin poz tahmini performansını değerlendirmek amacıyla yapılan analizlerde duyarlılık, F1 skoru, keskinlik ve keskinlik-duyarlılık eğrileri incelenmiştir. Şekil 29a’da verilen keskinlik-güven eğrisi, modelin en yüksek keskinlik (1,00) değerine 0,935 güven seviyesinde ulaştığını ortaya koymuştur. Bu, yüksek güven seviyelerinde modelin neredeyse hatasız tahmin yaptığını işaret etmektedir. Ancak düşük güven seviyelerinde keskinlik değerlerinde dalgalanmalar olduğu, bu nedenle düşük eşiklerde dikkatli olunması gerektiği anlaşılmaktadır. Şekil 29b’de verilen duyarlılık-güven eğrisi sonuçlarına göre, modelin genel

duyarlılık değeri 0,91 olarak hesaplanmış ve düşük güven seviyelerinde yüksek duyarlılık oranı elde edilmiştir. Ancak güven seviyesi arttıkça duyarlılık performansında belirgin bir düşüş gözlemlenmiştir. Bu durum, modelin daha düşük eşiklerde daha fazla doğru poz tahmini yapabildiğini ancak güven eşiği yükseldikçe daha seçici hale geldiğini göstermektedir. **Şekil 29c'**de verilen F1-güven eğrisine bakıldığında, tüm sınıflarda ortalama 0,70 F1 skoru elde edilmiştir ve en yüksek F1 performansı 0,64 civarındaki güven eşiğinde gerçekleşmiştir. Bu bulgu, modelin hassasiyet ve hatırlama dengesini en iyi bu eşik seviyesinde kurduğunu ve bu noktanın uygulamalarda optimal eşik olarak kullanılabileceğini göstermektedir. **Şekil 29d'**de verilen keskinlik-duyarlılık eğrisi ve mAP@0,5 değeri incelendiğinde, ortalaması 0,754 mAP değeri olup, bu sonuç modelin genel doğruluk kapasitesinin kabul edilebilir düzeyde olduğunu göstermektedir. Tüm bu sonuçların özeti **Tablo 11'** de verilmiştir.




Şekil 29. YOLOv12x-Pose modelinin performans sonuçları, a) keskinlik - güven grafiği, b) duyarlılık - güven grafiği, c) F1 - güven grafiği, d) keskinlik - duyarlılık grafiği.

Tablo 11. YOLOv12x-Pose Modelinin Maske İçin Performans Sonuçları


Nesne Adı	Kesinlik	Duyarlılık	mAP@0,5
Poz	0,748	0,664	0,756

Öznitelikleri Kullanarak Bitki Morfolojik Özelliklerinin Çıktıları

YOLOv12 algoritması kullanılarak segmentasyon ve poz tahmini görevleri için eğitilen modellerin .pth formatındaki çıktılar Python ortamında geliştirilen özel bir algoritmaya entegre edilmiştir. Bu sayede, bitki görüntülerinden bitkinin su ihtiyacına ilişkin anlamlı veriler çıkarılmıştır. **Şekil 30** ve **Şekil 31**'de, yapraklar, meyveler ve bitki için bölütleme sonuçlarına ait örnek verilmiştir. Şekillerde de görüldüğü gibi, bitki üzerindeki fiziksel özellikler doğru bir şekilde tespit edilmiştir. Geliştirilen algoritma kullanılarak, bölütlenmiş yaprak sayısı, toplam yaprak alanı, maksimum yaprak alanı, ortalama yaprak alanı, bölütlenmiş meyve sayısı, toplam meyve alanı, toplam bitki alanı, kamera yönü ve yaprak eğilme açısını içeren kapsamlı bir veri kümesi oluşturulmuştur. Alan ölçümlerinde doğruluğu sağlamak için piksel başına santimetrekare değeri, görüntülere yerleştirilen bir referans tahtasının alanına göre hesaplanmış ve tüm fiziksel ölçümler buna göre kalibre edilmiştir.




Şekil 30. a) Segmentasyon tahminini kullanan örnek görüntü, b) yaprak ve meyve segmentasyonu gösterimi




Şekil 31. Yaprak ve bitki segmentasyon çıktısı

Modelin poz tahmin çıktısının bir örneği **Şekil 32**'de verilmiştir. Bu model ile yaprak eğilme açısının belirlenmesinde kullanılacak noktaların yerleri görseller üzerinden tespit edilmiştir. Tespit edilen noktaların konum bilgileri kullanılarak Python ortamında yazılan kod yardımı ile **Şekil 33**'de verildiği gibi yaprağın yön bilgileri ile $\hat{A}$ açısı hesaplanmıştır.



Şekil 32. Poz tahmininde kullanılan referans noktaların çıktıları



Şekil 33. Poz tahmini kullanılarak elde edilen $\hat{A}$ açısının ve yaprak yönlerini gösteren çıktısı

Kc Tahmin Sonuçları

Tez çalışmasında önerilen yöntemin Kc tahminindeki etkinliğini sağlıklı biçimde değerlendirebilmek amacıyla, bu yöntemle paralel olarak aynı performans metriklerine dayalı sensör verilerinden elde edilen meteorolojik bilgiler ile ikinci bir YSA eğitim daha gerçekleştirilmiştir. Her iki eğitimde de yapay sinir ağı modelleri, benzer koşullar altında ancak farklı veri kaynakları kullanılarak (IoT tabanlı görsel veriler ve geleneksel meteorolojik veriler) eğitilmiş; böylece model performansları karşılaştırmalı olarak analiz edilmiştir.

Tez çalışmasında önerilen yöntemle Kc tahminindeki etkinliğin sağlıklı olarak değerlendirebilmek için, buna paralel olarak yine aynı performans metriklerinin elde edildiği verilere göre hesaplanmış ikinci bir metot daha geliştirilmiştir. Dolayısıyla her iki metotta aynı değer koşullar altında ancak farklı veri setleri (IoT tabanlı görsel veriler ve meteorolojik veriler) kullanılarak yapay sinir ağı modeli eğitilmiş ve performansları karşılaştırılmıştır. Bunun sonucunda elde edilen bulgular **Tablo 12**'de sunulmaktadır. Önerilen yöntemin yeterliliği ortaya konmuştur. Bu sonuçlar incelendiğinde, önerilen yöntemin performansı sadece meteorolojik verilerin kullanıldığı modele yaklaşık olarak aynı seviyelerde olduğu gözlemlenmiştir. Bu anlamda elde edilen R^2 değerinin bir miktar fazla olduğu görülmüştür.


Tablo 12. Kc Tahmin Sonuçları

Model	RMSE	MAPE	R ²
Meteorolojik Tabanlı Model	0,024	0,035	0,925
Görsel Veri Tabanlı Model	0,030	0,049	0,954

Bu sonuçlar, önerilen yöntemde kullanılan görsel verilerin yalnızca sensör tabanlı verilere alternatif olarak bağımsız bir tahmin aracı olacağı görülmektedir. Çalışmanın bulguları, sensörsüz tahmin modellerinin özellikle tarımsal uygulamalarda sürdürülebilir ve maliyet etkin çözümler geliştirilmesine katkı sunabileceğini ve görsel verilerin bu alandaki potansiyelini ortaya koymaktadır.

Öte yandan literatür çalışmalar incelendiğinde, Kc tahmin doğruluğu için elde edilen R² değerlerinin farklı çalışmalarda, 0,67 (Gautam et al., 2021), 0,94 (Marcial-Pablo et al., 2021) ve 0,98 (Malachy et al., 2022) olarak raporlandığı görülmektedir. Bu bağlamda, mevcut çalışmada elde edilen sonuçlar, literatürdeki bulgularla büyük ölçüde örtüşmekte ve benzer doğruluk seviyelerine ulaşarak yöntemin geçerliliğini desteklemektedir. Ayrıca, bu bulgular bitki morfolojisindeki değişimlerin su ihtiyacını yansıttığı yönündeki literatür bilgileriyle uyumlu olup, geliştirilen görsel analiz yönteminin Kc değerlerinin belirlenmesinde etkili ve yenilikçi bir araç olarak kullanılabileceğini doğrulamaktadır (Chen et al., 2019).

Şekil 34'de Kc değerleri ile bitki büyüme dönemlerinin ilişkili ve bunun bitkilerin görselleriyle bağlantısı olduğu açıkça görülmektedir. Bu görsel, birinci dönem dikim aşamasını ve ilk yaprakların çıkışını kapsamaktadır. Model, bu evrede ilk yaprakları algılayarak, yaprak sayısının azlığı ve düşük yaprak/bitki alanı değerlerinden hareketle erken büyüme evresini belirlemektedir. İkinci dönem, yeşil aksamın hızlı geliştiği evredir ve model, yaprak sayısındaki ve alanındaki artışa dayanarak bu dönemi tanımlamaktadır. Üçüncü dönemde çiçeklenme ve meyve oluşumu gözlenmekte olup, model, tomurcuklanmanın başlaması, çiçek ve meyve sayısındaki artış gibi değişkenleri kullanarak bu büyüme evresini tespit etmektedir. Son aşama olan dördüncü dönem ise hasat aşamasıdır; bu dönemde model, yaprak sayısı ve alanındaki azalma ile toplam bitki alanındaki düşüş gibi parametreleri analiz ederek bitkinin olgunlaşma evresine ulaştığını belirleyebilmektedir. Böylece model, bir sezon boyunca bitkinin gelişim aşamalarını izleyerek, her döneme uygun Kc değerini yüksek doğrulukla tahmin edebilmekte ve tarım uygulayıcıları için sulama yönetiminde kritik bir parametre sunmaktadır.




Şekil 34. Kc ile bitki görselleri arasındaki ilişki

Günümüzde, İHA veya uydu tabanlı uzaktan algılama sistemleri de bitki örtüsü indeksi temelli yaklaşımlar kullanarak Kc tahminleri yapmaktadır (de la Fuente-Saiz et al., 2024; Sabie et al., 2024; Xu et al., 2025b). Ancak bu yöntemlerde saha uygulama maliyeti oldukça yüksek olup uygulanabilirlik sınırlanmaktadır. Daha düşük maliyetli olan tez çalışması bu yaklaşımlara benzer bir yöntem izlemekle birlikte, daha fazla görsel özellik kullanarak, sezon boyunca oluşabilecek ani değişimlere karşı daha duyarlı bir tahmin modeli sunmaktadır. Nitekim önceki çalışmalar da bu tür sistemlerin sınırlılıklarına dikkat çekmiştir (Xu et al., 2025b). Ancak, araştırmamızın orta ve küçük ölçekli tarım alanlarına daha uygun olduğu sonucu verilmiştir. Buna karşın İHA ve uydu tabanlı sistemlerin büyük ölçekli tarım alanlarında genellenebilirlik açısından daha avantajlı olduğu görülmektedir. Modelimizin büyük tarım arazilerine entegrasyonu için izleme istasyonlarının farklı iklim ve toprak koşullarına göre konumlandırılması gerekmektedir. Ayrıca, geliştirilen sistem, haşere ve hastalık tespiti ile verim analizi gibi tarımsal izleme süreçlerine entegre edilebilir yapıda olup, uygulanabilirliğini artırma potansiyeline sahiptir.


ETc Tahmin Sonuçları

Önerilen çalışmanın ikinci ve en önemli çıktısı, bitki görsellerinin su stresi belirlemede nasıl kullanılabileceğidir. Literatürde bu konuyla ilgili yapılan araştırmalar incelendiğinde, bitkilerin genellikle stresli veya stressiz olarak sınıflandırıldığı görülmektedir (Narendra S. Chandel et al., 2022; Narendra Singh Chandel et al., 2021b, 2024). Bu yaklaşım, sulama yönetimi için temel bir veri sağlasa da bitkinin su stresine hangi seviyede maruz kaldığını belirleyememektedir. Bu eksiklikten hareketle, tez çalışması öncelikle bitkinin stresli olup olmadığını, literatürdeki çalışmalara benzer şekilde tespit edilebilirliği kontrol edilmiştir. Bu


doğrultuda, yaprak eğilme açısı ile bitki su stresi arasındaki ilişkiyi belirlemek amacıyla Python ortamında bir algoritma geliştirilmiştir. Bu algoritma, poz tahmini sonuçlarından elde edilen referans noktaları kullanarak yaprağın eğilme açısını hesaplamış ve bu açı değerleri de önerilen modele bir girdi olarak kullanılmıştır. Analizler sonucunda, yaprak eğilme açısının 170-180 derece arasında olması, bitkinin su stresine maruz kalmadığını, 170 dereceden küçük olması da su stresinin varlığını göstermiştir. Örnek olarak **Şekil 35**'de görüldüğü üzere bitki yaprağında 163 derecelik bir $\hat{A}$ açısı, bitkinin su stresinin varlığına işaret etmektedir. Öte yandan **Şekil 36**'da verilen örnekte ise $\hat{A}$ açısının 157 derece olmasına rağmen, daha önce açıklandığı üzere (**Şekil 22**) bunun yaprakta bir anomali kaynaklı olduğu ve bitkinin su stresinde olmadığı bir örneği ifade etmektedir. Benzer şekilde **Şekil 37**'de 167 derecelik açının +Y yönünde olduğundan dolayı yine bitkinin su stresinde olmadığı bir örnek olarak değerlendirilmiştir. Bu durumun temel nedeni +Y yönünde olan yaprakların yaprak uç noktasının yukarı yönlü olması nedeni ile su stresi belirlemede etkin olmamasıdır. Sonuç olarak yaprağın eğildiği -Y yönü ve eğilme açısını ifade eden $\hat{A}$ değeri su stresinin belirlenmesinde kullanılmıştır. Ayrıca elde edilen açı değerlerinden her bitki için en düşük açıya göre durum belirlemesi yapılmıştır. Örnek olarak **Şekil 38**'de ve **Şekil 39**'da görsellerindeki A açısı sırası ile 174 ve 164 olarak kaydedilmiştir. Bu açılara göre su stresi durumu açı küçüldükçe arttığı bitki görsellerinden anlaşılmaktadır.




Şekil 35. Yaprak eğilme açıları gösterimi, su stresinin başladığını gösteren görsel




Şekil 36. Eksene düz olan yaprağın bulunduğu görsel



Şekil 37. +Y yönünde 170 dereceden düşük açının olduğu görsel



Şekil 38. Su stresinin arttığını gösteren görsel.



Şekil 39. Su stresinin arttığını gösteren görsel.

$\hat{A}$ açısının sonuca etkisini tespit etmek için gerçekleştirilen deneysel çalışmalarda, önerilen modelin hem $\hat{A}$ açısı kullanılmaksızın hem de $\hat{A}$ açısı dahil edilerek analiz sonuçları elde edilmiş ve **Tablo 13**'de karşılaştırılmıştır. Burada meteorolojik verilere dayalı model ile elde edilen performans metrikleri nispeten sınırlı bir tahmin performansı sergilemiştir. $\hat{A}$ açısının kullanılmadığı durumda iyileştirmeler tespit edilmiştir. Bu anlamda RMSE değeri yaklaşık olarak yarıya düşerken R^2 değeri yaklaşık olarak %41 oranında iyileşmiştir. Buna ek olarak $\hat{A}$ açısının önerilen modele dahil edilmesi ile modelin performansı önemli ölçüde artmış ve R^2 0,974 değerlerine ulaşılmıştır.

Tablo 13. ETc Tahmin Sonuçları

Yöntem	RMSE	MAPE	R ²
Meteorolojik Verilerin Kullanıldığı Yöntem	0,111	0,314	0,591
Sadece Görsel Verilerin Kullanıldığı Yöntem	0,066	0,173	0,833
Görsel Verilerin ve Â Açısının Kullanıldığı Yöntem	0,029	0,053	0,974

Bunun yanı sıra önerilen yöntemin performansını daha iyi ifade edebilmek için elde edilen Kc ve ETc değerlerinin **Tablo 14**'te literatürde yer alan benzer çalışmalarla karşılaştırması bir arada verilmiştir. Buna göre Â açısının kullanılması önerilen yöntemin performansının literatürdeki yüksek maliyetli diğer yöntemlere göre benzer ve hatta daha iyi olduğunu göstermektedir. Ayrıca, tez çalışması literatürdeki benzer araştırmalardan önemli bir noktada farklılaşmaktadır. Mevcut literatürde genellikle bitkiler sadece stresli veya stressiz olarak iki sınıfa ayrılarak değerlendirilirken (Narendra S. Chandel et al., 2022; Narendra Singh Chandel et al., 2021b, 2024), çalışmamız su ihtiyacını doğrudan belirleyebilen düzeltici bir katsayı sunmaktadır.

Tablo 14. Literatürdeki Benzer Çalışmaların Kıyaslaması

Çalışma Referans	Tahmin	Kullanılan Teknoloji	Başarı Değeri
(Narendra Singh Chandel et al., 2024)	Stres	YZ, RGB görüntüleri	Accuracy(%) 97,9
(Narendra S. Chandel et al., 2022)	Stres	YZ, termal görüntüler	Accuracy(%) 96,9
(Zeyliger & Ermolaeva, 2021)	Stres	Uzaktan algılama ve yer tabanlı yöntemler, meteorolojik veri	R ² =0,743
(Briglia et al., 2020)	Stres	3D görüntüleme ve fiziki ölçüm, yaprak açısı	R ² =0.86 (manuel) 0.73 (3D)
(Singh et al., 2025)	Etc	NDVI	R ² =0,97
(Ferreira et al., 2025)	Etc	NDVI	R ² = 0,75
(Gautam et al., 2021)	Kc	İHA görüntüleri, kanopi yapısı	R ² =0,675
(Marcial-Pablo et al., 2021)	Kc	İHA görüntüleri, bitki indeksleri ve bitki örtüsü oranları	R ² =0,94
	Etc	Yapay Zeka, RGB Görüntüler, Bitkinin morfolojik özellikleri, Â açısı	R ² =0,97
Tez Çalışması	Kc	Yapay Zeka, RGB Görüntüler, Bitkinin morfolojik özellikleri	R ² =0,95

SONUÇLAR VE ÖNERİLER

Bu çalışma, bitki ETc tahmininde görsel verilere ve yapay zekâya dayalı yenilikçi ve erişilebilir bir yaklaşım sunmaktadır. Geleneksel ETc tahmin yöntemleri genellikle meteorolojik sensörlere ve kapsamlı çevresel verilere bağımlıyken, tez çalışması, düşük maliyetli ve sadece RGB görüntülerden bitki morfolojik özelliklerini (yaprak alanı, meyve sayısı, yaprak eğilme açısı gibi) çıkararak anlamlı bilgiler elde edebilen görüntü tabanlı sistemlerin potansiyelini ortaya koymaktadır.

Sonuçlar, geliştirilen görsel veri tabanlı yapay sinir ağı modelinin Kc ve ETc değerlerini yüksek doğrulukla (sırasıyla $R^2 = 0,95$ ve $0,97$) tahmin edebildiğini ve geleneksel sensör tabanlı modellere kıyasla üstün veya en az eşdeğer bir performans sergilediğini göstermektedir. Özellikle, düzeltici bir parametre olarak yaprak eğilme açısının modele dahil edilmesi, ETc tahmin performansını önemli ölçüde artırmış; RMSE ve MAPE değerlerini düşürerek modelin genel dayanıklılığını güçlendirmiştir. Bu bulgu, bitkinin su stresini yalnızca stresli veya stressiz olarak sınıflandırmanın ötesine geçip, sürekli ve nicel bir su ihtiyacı değerlendirmesi yapabilmek için morfolojik göstergelerin entegrasyonunun önemini vurgulamaktadır.

Gerçekleştirilen deneysel çalışmalar sonucunda, 170 derece üzerindeki yaprak açıları bitkilerin su stresine maruz kalmadığını, 170 dereceden düşük değerler ise stres belirtisi taşıdığını göstermiştir. Ancak yalnızca açı değerine dayalı sınıflandırmaların yanıltıcı olabileceği durumlar tespit edilmiştir. Bu nedenle çalışmada, yaprak uç noktasının yönelimi de değerlendirmeye katılmış ve X-Y düzlemindeki yön bilgisi yardımıyla açının geçerliliği kontrol edilmiştir. Böylece, poz tahmini hataları ya da yaprak sağlığından kaynaklanan anomalilerin etkisi azaltılmıştır.

Tez çalışması, düşük çözünürlüklü ve IoT ile entegre edilmiş kameralarla dahi güvenilir segmentasyon ve poz tahmini yapılabildiğini doğrulamış ve bu yaklaşımın yalnızca düşük maliyetli değil, aynı zamanda orta ve küçük ölçekli tarım sistemleri için ölçeklenebilir bir çözüm sunduğunu göstermiştir. Geliştirilen sistem, diğer bitki türlerine de genişletilebilir ve akıllı tarım platformlarına entegre edilerek gerçek zamanlı, yerel sulama yönetimi yapılmasına olanak tanıyarak, yüksek çözünürlüklü pahalı ekipmanlara veya karmaşık uydu tabanlı sistemlere olan ihtiyacı azaltabilir.

Ayrıca tez çalışması kapsamında gerçekleştirilen karşılaştırmalı analizler sonucunda, IoT verilerinin işlenmesinde kullanılan veri tabanı türlerinin sistem performansına etkileri detaylı şekilde ortaya konmuştur. Yapılan testler, Firebase gibi NoSQL temelli bulut veri tabanlarının, özellikle hızlı veri kaydının kritik olduğu uygulamalarda, SQLite'a kıyasla önemli hız avantajları sunduğunu göstermiştir. Buna karşılık, SPIFFS dosya sistemi üzerinde çalışan SQLite, daha küçük veri kümelerinde sorgu işlemleri açısından daha verimli sonuçlar vermiştir. Ayrıca, SPIFFS + SQLite kombinasyonunun çok yüksek hacimlerinde yanıt verememesi, LittleFS + SQLite sisteminin daha büyük veri yapıları için daha uygun olabileceğini ortaya koymuştur. Bu bulgular doğrultusunda, tez çalışmasında çevrimdışı çalışma gereksinimi olan sulama verileri SPIFFS + SQLite sistemi ile yerel olarak kaydedilmiş; YZ eğitimlerinde kullanılacak büyük hacimli sensör verileri ve görsel içerikler ise Firebase altyapısına aktarılmıştır.

Sonuç olarak tez çalışması, görsel verilerin, en ileri derin öğrenme modelleriyle birleştirildiğinde, geleneksel sensör tabanlı ETc tahmin yöntemlerini etkili bir şekilde tamamlayabileceğini veya yerini alabileceğini göstermektedir. Önerilen yaklaşım, su kullanım verimliliğini artırmak, gereksiz sulama uygulamalarını azaltmak ve çeşitli çevresel koşullar altında veri odaklı tarımsal yönetimi desteklemek için önemli bir yol sunmaktadır. Gelecekte yapılacak çalışmalar, bu yöntemin farklı iklim bölgelerine uygulanması, çok modlu veri entegrasyonu (örneğin RGB, termal ve multispektral görüntüler bir arada) ve poz tahmin doğruluğunun artırılması üzerine odaklanarak su kaynakları yönetiminin daha da optimize edilmesine katkı sağlayabilir. Ayrıca tez çalışmasında çiçeklerin tespiti içinde bir çalışma yürütülmüş fakat görsellerin kalitesi ve çözünürlüğü kısıtlı olduğu için istenilen başarımlar elde edilemediğinden dolayı önerilen yöntemden çıkartılmıştır. Gelecek çalışmalarda gelişen teknoloji ile maliyeti artırmadan görüntü kalitesinin artırılması ile çiçek sayısı gibi yeni girdi sayesinde tahmin başarımlarının artırılacağı düşünülmektedir.

KAYNAKÇA

- Adamo, T., Caivano, D., Colizzi, L., Dimauro, G., & Guerriero, E. (2025). Optimization of irrigation and fertigation in smart agriculture: An IoT-based micro-services framework. *Smart Agricultural Technology*, 11(2025), 100885. <https://doi.org/10.1016/j.atech.2025.100885>
- Ahmad, U., Alvino, A., & Marino, S. (2021). A Review of Crop Water Stress Assessment Using Remote Sensing. *Remote Sensing*, 13(20), 4155. <https://doi.org/10.3390/rs13204155>
- Ahmed, N., De, D., & Hussain, I. (2018). Internet of Things (IoT) for Smart Precision Agriculture and Farming in Rural Areas. *IEEE Internet of Things Journal*, 5(6), 4890–4899. <https://doi.org/10.1109/JIOT.2018.2879579>
- Al Mamun, M. R., Ahmed, A. K., Upoma, S. M., Haque, M. M., & Ashik-E-Rabbani, M. (2025). IoT-enabled solar-powered smart irrigation for precision agriculture. *Smart Agricultural Technology*, 10(2024), 100773. <https://doi.org/10.1016/j.atech.2025.100773>
- Alegewe, R., Shaibu, A.-G., & Zakaria, Y. S. (2023). Optimization of Water Management for Green Pepper Production in a Water-Limiting Tropical Savanna Agroecological Zone Based on Crop Water Productivity. *Journal of Engineering*, 2023, 1–9. <https://doi.org/10.1155/2023/9970714>
- Alturif, G., Saleh, W., El-Bary, A. A., & Osman, R. A. (2024). Towards efficient IoT communication for smart agriculture: A deep learning framework. *PLoS ONE*, 19(11 November), e0311601. <https://doi.org/10.1371/journal.pone.0311601>
- Anagha, C. S., Pawar, P. M., & Tamizharasan, P. S. (2023). Cost-effective IoT-based intelligent irrigation system. *International Journal of System Assurance Engineering and Management*, 0123456789. <https://doi.org/10.1007/s13198-023-01854-y>
- Anjum, S. A., Farooq, M., Xie, X. yu, Liu, X. jian, & Ijaz, M. F. (2012). Antioxidant defense system and proline accumulation enables hot pepper to perform better under drought. *Scientia Horticulturae*, 140, 66–73. <https://doi.org/10.1016/j.scienta.2012.03.028>
- Ayaz, M., Ammad-Uddin, M., Sharif, Z., Mansour, A., & Aggoune, E. H. M. (2019). Internet-of-Things (IoT)-based smart agriculture: Toward making the fields talk. *IEEE Access*, 7, 129551–129583. <https://doi.org/10.1109/ACCESS.2019.2932609>
- Bai, R., Wang, M., Zhang, Z., Lu, J., & Shen, F. (2023). Automated Construction Site Monitoring Based on Improved YOLOv8-seg Instance Segmentation Algorithm. *IEEE Access*, 11, 139082–139096. <https://doi.org/10.1109/ACCESS.2023.3340895>
- Balamurali, D., Chakankar, S., Sharma, G., Pagey, A. P., Natarajan, M., Shaik, S., Gnanavendan, S., & Arıcı, M. (2025). A solar-powered, internet of things (IoT)-controlled water irrigation system supported by rainfall forecasts utilizing aerosols: a review. *Environment, Development and Sustainability*, 0123456789. <https://doi.org/10.1007/s10668-024-05953-z>
- Belkher, S., Latrech, B., Bekri, W., Markwordt, F., Rahim, M. A., Dupont, C., Ben Abdallah, M. A., Daghari, H., & Rezig, M. (2025). Deficit Irrigation and an IoT-Based System for Improving Yield and Water Use Efficiency of Winter Wheat Grown Under Semi-Arid Conditions. *Agronomy*, 15(1). <https://doi.org/10.3390/agronomy15010157>
- Briglia, N., Williams, K., Wu, D., Li, Y., Tao, S., Corke, F., Montanaro, G., Petrozza, A., Amato, D., Cellini, F., Doonan, J. H., Yang, W., & Nuzzo, V. (2020). Image-Based

- Assessment of Drought Response in Grapevines. *Frontiers in Plant Science*, 11, 528916. <https://doi.org/10.3389/fpls.2020.00595>
- Camacho, J. C., & Morocho-Cayamcela, M. E. (2023). Mask R-CNN and YOLOv8 Comparison to Perform Tomato Maturity Recognition Task. *Communications in Computer and Information Science*, 1885 CCIS, 382–396. https://doi.org/10.1007/978-3-031-45438-7_26
- Chandel, Narendra S., Rajwade, Y. A., Dubey, K., Chandel, A. K., Subeesh, A., & Tiwari, M. K. (2022). Water Stress Identification of Winter Wheat Crop with State-of-the-Art AI Techniques and High-Resolution Thermal-RGB Imagery. *Plants*, 11(23), 3344. <https://doi.org/10.3390/plants11233344>
- Chandel, Narendra Singh, Chakraborty, S. K., Chandel, A. K., Dubey, K., A. S., Jat, D., & Rajwade, Y. A. (2024). State-of-the-art AI-enabled mobile device for real-time water stress detection of field crops. *Engineering Applications of Artificial Intelligence*, 131, 107863. <https://doi.org/10.1016/j.engappai.2024.107863>
- Chandel, Narendra Singh, Chakraborty, S. K., Rajwade, Y. A., Dubey, K., Tiwari, M. K., & Jat, D. (2021a). Identifying crop water stress using deep learning models. *Neural Computing and Applications*, 33(10), 5353–5367. <https://doi.org/10.1007/s00521-020-05325-4>
- Chandel, Narendra Singh, Chakraborty, S. K., Rajwade, Y. A., Dubey, K., Tiwari, M. K., & Jat, D. (2021b). Identifying crop water stress using deep learning models. *Neural Computing and Applications*, 33(10), 5353–5367. <https://doi.org/10.1007/s00521-020-05325-4>
- Cheema, S. J., Karbasi, M., Randhawa, G. S., Liu, S., Esau, T. J., Grewal, K. S., Abbas, F., Zaman, Q. U., & Farooque, A. A. (2025). A state-of-the-art novel approach to predict potato crop coefficient (Kc) by integrating advanced machine learning tools. *Smart Agricultural Technology*, 11, 100896. <https://doi.org/10.1016/j.atech.2025.100896>
- Chen, Z., Xu, J., Wang, F., Wang, L., & Xu, Z. (2019). Morpho-physiological and proteomic responses to water stress in two contrasting tobacco varieties. *Scientific Reports*, 9(1), 18523. <https://doi.org/10.1038/s41598-019-54995-1>
- de la Fuente-Saiz, D., Ortega-Farias, S., Carrasco-Benavides, M., Ortega-Salazar, S., Tian, F., Wang, S., & Liu, Y. (2024). Assessment of satellite-based water requirements for a drip-irrigated apple orchard in Mediterranean agroclimatic conditions. *Heliyon*, 10(9), e29688. <https://doi.org/10.1016/j.heliyon.2024.e29688>
- Dong, S., Ma, Q., Yu, C., Li, L., Liu, H., Cui, G., Qiu, H., Yang, S., & Wang, G. (2025). Comparative Analysis of Crop Coefficient Approaches and Machine Learning Models for Predicting Water Requirements in Three Major Crops in Coastal Saline-Alkali Land. *Agronomy*, 15(2), 492. <https://doi.org/10.3390/agronomy15020492>
- Eludire, O., Faloye, O., Alatise, M., Ajayi, A., Oguntunde, P., Badmus, T., Fashina, A., Adeyeri, O., Olorunfemi, I., & Ogunrinde, A. (2025). Evaluation of Evapotranspiration Prediction for Cassava Crop Using Artificial Neural Network Models and Empirical Models over Cross River Basin in Nigeria. *Water*, 17(1), 87. <https://doi.org/10.3390/w17010087>
- Farooq, M. S., Javid, R., Riaz, S., & Atal, Z. (2022). IoT Based Smart Greenhouse Framework and Control Strategies for Sustainable Agriculture. *IEEE Access*, 10(July), 99394–99420. <https://doi.org/10.1109/ACCESS.2022.3204066>
- Ferreira, S., Sánchez, J. M., Gonçalves, J. M., Eugénio, R., & Damásio, H. (2025). Remote Sensing-Assisted Estimation of Water Use in Apple Orchards with Permanent Living

- Mulch. *Agronomy*, 15(2), 338. <https://doi.org/10.3390/agronomy15020338>
- Gago, J., Douthe, C., Coopman, R. E., Gallego, P. P., Ribas-Carbo, M., Flexas, J., Escalona, J., & Medrano, H. (2015). UAVs challenge to assess water stress for sustainable agriculture. *Agricultural Water Management*, 153, 9–19. <https://doi.org/10.1016/j.agwat.2015.01.020>
- Gautam, D., Ostendorf, B., & Pagay, V. (2021). Estimation of grapevine crop coefficient using a multispectral camera on an unmanned aerial vehicle. *Remote Sensing*, 13(13), 2639. <https://doi.org/10.3390/rs13132639>
- Gou, C., Zafar, S., Fatima, Hasnain, Z., Aslam, N., Iqbal, N., Abbas, S., Li, H., Li, J., Chen, B., Ragauskas, A. J., & Abbas, M. (2024). Machine and Deep Learning: Artificial Intelligence Application in Biotic and Abiotic Stress Management in Plants. In *Frontiers in Bioscience - Landmark* (Vol. 29, Issue 1, p. 20). IMR Press Limited. <https://doi.org/10.31083/j.fbl2901020>
- Gültaş, H. T. (2025). Crop water stress index assessment of safflower (*Carthamus tinctorius* L.) under limited water conditions. *Scientia Agricola*, 82, e20230285. <https://doi.org/10.1590/1678-992x-2023-0285>
- Gündüz, M. Ş., & Işık, G. (2023). A new YOLO-based method for social distancing from real-time videos. *Neural Computing and Applications*, 35(21), 15261–15271. <https://doi.org/10.1007/s00521-023-08556-3>
- Han, X., Wei, Z., Zhang, B., Li, Y., Du, T., & Chen, H. (2021). Crop evapotranspiration prediction by considering dynamic change of crop coefficient and the precipitation effect in back-propagation neural network model. *Journal of Hydrology*, 596, 126104. <https://doi.org/10.1016/j.jhydrol.2021.126104>
- Hou, Y., Yang, Q., Li, L., & Shi, G. (2023). *Detection and Recognition Algorithm of Arbitrary-Oriented Oil*.
- Hu, Z., Bashir, R. N., Rehman, A. U., Iqbal, S. I., Shahid, M. M. A., & Xu, T. (2022). Machine Learning Based Prediction of Reference Evapotranspiration (ET₀) Using IoT. *IEEE Access*, 10(May), 70526–70540. <https://doi.org/10.1109/ACCESS.2022.3187528>
- Ihuoma, S. O., & Madramootoo, C. A. (2017). Recent advances in crop water stress detection. *Computers and Electronics in Agriculture*, 141, 267–275. <https://doi.org/10.1016/j.compag.2017.07.026>
- Irianto, K. D., & Rif'an, M. (2024). *Precision Agriculture System with IoT: An Approach to Increase Production and Efficiency*. OSF. <https://doi.org/10.31219/osf.io/mux9c>
- Isa, I. G. T., Effendi, A., & Suhartono. (2024). Deep reinforcement learning in agricultural IoT-based: A review. *E3S Web of Conferences*, 479, 07004. <https://doi.org/10.1051/e3sconf/202447907004>
- Jang, M., & Hwang, Y. (2024). Tomato pose estimation using the association of tomato body and sepal. *Computers and Electronics in Agriculture*, 221, 108961. <https://doi.org/10.1016/j.compag.2024.108961>
- Jocher, G., & Qiu, J. (2024). *Ultralytics YOLO11*. <https://github.com/ultralytics/ultralytics>
- Ju, R. Y., & Cai, W. (2023). Fracture detection in pediatric wrist trauma X-ray images using YOLOv8 algorithm. *Scientific Reports*, 13(1), 1–13. <https://doi.org/10.1038/s41598-023-47460-7>
- Kamble, B., Kilic, A., & Hubbard, K. (2013). Estimating crop coefficients using remote sensing-based vegetation index. *Remote Sensing*, 5(4), 1588–1602.

<https://doi.org/10.3390/rs5041588>

- Kapari, M., Sibanda, M., Magidi, J., Mabhaudhi, T., Mpandeli, S., & Nhamo, L. (2025). Assessment of the Maize Crop Water Stress Index (CWSI) Using Drone-Acquired Data Across Different Phenological Stages. *Drones*, 9(3), 192. <https://doi.org/10.3390/drones9030192>
- Kashyap, P. S., & Panda, R. K. (2001). Evaluation of evapotranspiration estimation methods and development of crop-coefficients for potato crop in a sub-humid region. *Agricultural Water Management*, 50(1), 9–25. [https://doi.org/10.1016/S0378-3774\(01\)00102-0](https://doi.org/10.1016/S0378-3774(01)00102-0)
- Keabetswe, L., He, Y., Li, C., & Zhou, Z. (2024). Estimating actual crop evapotranspiration by using satellite images coupled with hybrid deep learning-based models in potato fields. *Agricultural Water Management*, 306, 109191. <https://doi.org/10.1016/j.agwat.2024.109191>
- Khan, A. T., & Jensen, S. M. (2024). LEAF-Net: A Unified Framework for Leaf Extraction and Analysis in Multi-Crop Phenotyping Using YOLOv11. In *Agriculture* (Vol. 15, Issue 2, p. 196). <https://doi.org/10.21203/rs.3.rs-5582314/v1>
- Lawal, M. O. (2021). Tomato detection based on modified YOLOv3 framework. *Scientific Reports*, 11(1), 1–11. <https://doi.org/10.1038/s41598-021-81216-5>
- Liu, C., Khalid, N. A., & Ramli, M. I. (2024). Distributed communication in smart agriculture at vineyard of Liangshan, China. In Y. Zhao & Y. Xu (Eds.), *Fourth International Conference on Optics and Communication Technology (ICOCT 2024)* (Vol. 13398, p. 65). SPIE. <https://doi.org/10.1117/12.3050310>
- Liu, M., Yang, M., & Yang, H. (2023). SimET: An open-source tool for estimating crop evapotranspiration and soil water balance for plants with multiple growth cycles. *Crop Journal*, 11(5), 1579–1585. <https://doi.org/10.1016/j.cj.2023.03.008>
- Lou, H., Duan, X., Guo, J., Liu, H., Gu, J., Bi, L., & Chen, H. (2023). DC-YOLOv8: Small-Size Object Detection Algorithm Based on Camera Sensor. *Electronics (Switzerland)*, 12(10), 1–14. <https://doi.org/10.3390/electronics12102323>
- Ma, M., & Pang, H. (2023). SP-YOLOv8s: An Improved YOLOv8s Model for Remote Sensing Image Tiny Object Detection. *Applied Sciences (Switzerland)*, 13(14). <https://doi.org/10.3390/app13148161>
- Malachy, N., Zadak, I., & Rozenstein, O. (2022). Comparing Methods to Extract Crop Height and Estimate Crop Coefficient from UAV Imagery Using Structure from Motion. In *Remote Sensing* (Vol. 14, Issue 4, p. 810). Multidisciplinary Digital Publishing Institute. <https://doi.org/10.3390/rs14040810>
- Mao, L., Lu, S., Liu, L., Li, Z., Wang, B., Pei, D., & Bai, Y. (2025). Determining water status of walnut orchards using the crop water stress index and canopy temperature measurements. *Plant Methods*, 21(1), 47. <https://doi.org/10.1186/s13007-025-01364-x>
- Marcial-Pablo, M. de J., Ontiveros-Capurata, R. E., Jiménez-Jiménez, S. I., & Ojeda-Bustamante, W. (2021). Maize crop coefficient estimation based on spectral vegetation indices and vegetation cover fraction derived from uav-based multispectral images. *Agronomy*, 11(4), 668. <https://doi.org/10.3390/AGRONOMY11040668>
- Mat Toridi, N., Nor Jalal, M. M. I., Wayayok, A., & Mohamed Zawawi, M. A. (2025). Determination of Optimal Water Requirement for Sweet Corn Crop Based on Meteorological Data and Plant Growth Parameters. *Pertanika Journal of Science and Technology*, 33(2). <https://doi.org/10.47836/pjst.33.2.03>

- Morchid, A., Muhammad Alblushi, I. G., Khalid, H. M., El Alami, R., Sitaramanan, S. R., & Muyeen, S. M. (2024). High-technology agriculture system to enhance food security: A concept of smart irrigation system using Internet of Things and cloud computing. *Journal of the Saudi Society of Agricultural Sciences*. <https://doi.org/10.1016/j.jssas.2024.02.001>
- Moseki, O., Kanguuehi, G., Chiteculo, V., Zink, M., & Wanga, M. A. (2025). Agro-Physiological and Morphological Responses of Pearl Millet to Varying Water Regimes in Semi-Arid Conditions of Namibia. *Agronomy*, 15(2), 381. <https://doi.org/10.3390/agronomy15020381>
- Nauman, M. A., Saeed, M., Saidani, O., Javed, T., Almuqren, L., Bashir, R. N., & Jahangir, R. (2023). IoT and Ensemble Long-Short-Term-Memory-Based Evapotranspiration Forecasting for Riyadh. *Sensors*, 23(17), 7583. <https://doi.org/10.3390/s23177583>
- Nawandar, N. K., & Satpute, V. R. (2019). IoT based low cost and intelligent module for smart irrigation system. *Computers and Electronics in Agriculture*, 162(December 2018), 979–990. <https://doi.org/10.1016/j.compag.2019.05.027>
- Palomar-Cosín, E., & García-Valls, M. (2022). Flexible IoT Agriculture Systems for Irrigation Control Based on Software Services. *Sensors*, 22(24). <https://doi.org/10.3390/s22249999>
- Paria, A., Giri, A., Dutta, S., & Neogy, S. (2025). Smart Irrigation for Coriander Plant: Saving Water with AI and IoT. *Water Resources Management*, 2050(Kumar 2023). <https://doi.org/10.1007/s11269-025-04112-x>
- Pathmudi, V. R., Khatri, N., Kumar, S., Abdul-Qawy, A. S. H., & Vyas, A. K. (2023). A systematic review of IoT technologies and their constituents for smart and sustainable agriculture applications. *Scientific African*, 19, e01577. <https://doi.org/10.1016/j.sciaf.2023.e01577>
- Paul, A., Machavaram, R., Ambuj, Kumar, D., & Nagar, H. (2024). Smart solutions for capsicum Harvesting: Unleashing the power of YOLO for Detection, Segmentation, growth stage Classification, Counting, and real-time mobile identification. *Computers and Electronics in Agriculture*, 219, 108832. <https://doi.org/10.1016/j.compag.2024.108832>
- Paul, N., Sunil, G. C., Horvath, D., & Sun, X. (2025). Deep learning for plant stress detection: A comprehensive review of technologies, challenges, and future directions. *Computers and Electronics in Agriculture*, 229, 109734. <https://doi.org/10.1016/j.compag.2024.109734>
- Peeters, A., Cohen, Y., Bahat, I., Ohana-Levi, N., Goldshtein, E., Netzer, Y., R. Tenreiro, T., Alchanatis, V., & Ben-Gal, A. (2024). A spatial machine-learning model for predicting crop water stress index for precision irrigation of vineyards. *Computers and Electronics in Agriculture*, 227, 109578. <https://doi.org/10.1016/j.compag.2024.109578>
- Pestana, D., Miranda, P. R., Lopes, J. D., Duarte, R. P., Vestias, M. P., Neto, H. C., & De Sousa, J. T. (2021). A Full Featured Configurable Accelerator for Object Detection with YOLO. *IEEE Access*, 9, 75864–75877. <https://doi.org/10.1109/ACCESS.2021.3081818>
- Pôças, I., Paço, T. A., Paredes, P., Cunha, M., & Pereira, L. S. (2015). Estimation of actual crop coefficients using remotely sensed vegetation indices and soil water balance modelled data. *Remote Sensing*, 7(3), 2373–2400. <https://doi.org/10.3390/rs70302373>
- Qiu, R., Liu, C., Cui, N., Wu, Y., Wang, Z., & Li, G. (2019). Evapotranspiration estimation

- using a modified Priestley-Taylor model in a rice-wheat rotation system. *Agricultural Water Management*, 224, 105755. <https://doi.org/10.1016/j.agwat.2019.105755>
- Rahim, U. F., Utsumi, T., & Mineno, H. (2022). Deep learning-based accurate grapevine inflorescence and flower quantification in unstructured vineyard images acquired using a mobile sensing platform. *Computers and Electronics in Agriculture*, 198, 107088. <https://doi.org/10.1016/j.compag.2022.107088>
- Reta, B. G., Yohannise, G. M., & Birhan, T. S. (2025). Dual Crop Coefficient of Watermelon under Deficit Irrigation, Mulching, and AquaCrop Model Performance in Arba Minch, Ethiopia. *Journal of Irrigation and Drainage Engineering*, 151(1), 04024036. <https://doi.org/10.1061/JIEDDH.IRENG-10336>
- Rodríguez-Lira, D. C., Córdova-Esparza, D. M., Álvarez-Alvarado, J. M., Romero-González, J. A., Terven, J., & Rodríguez-Reséndiz, J. (2024). Comparative Analysis of YOLO Models for Bean Leaf Disease Detection in Natural Environments. *AgriEngineering*, 6(4), 4585–4603. <https://doi.org/10.3390/agriengineering6040262>
- Rong, J., Dai, G., & Wang, P. (2022). A peduncle detection method of tomato for autonomous harvesting. *Complex and Intelligent Systems*, 8(4), 2955–2969. <https://doi.org/10.1007/s40747-021-00522-7>
- Rossi, R., Costafreda-Aumedes, S., Leolini, L., Leolini, C., Bindi, M., & Moriondo, M. (2022). Implementation of an algorithm for automated phenotyping through plant 3D-modeling: A practical application on the early detection of water stress. *Computers and Electronics in Agriculture*, 197, 106937. <https://doi.org/10.1016/j.compag.2022.106937>
- Roy, A. M., & Bhaduri, J. (2022). Real-time growth stage detection model for high degree of occultation using DenseNet-fused YOLOv4. *Computers and Electronics in Agriculture*, 193(January), 106694. <https://doi.org/10.1016/j.compag.2022.106694>
- Sabie, R., Bawazir, A. S., Buenemann, M., Steele, C., & Fernald, A. (2024). Calculating Vegetation Index-Based Crop Coefficients for Alfalfa in the Mesilla Valley, New Mexico Using Harmonized Landsat Sentinel-2 (HLS) Data and Eddy Covariance Flux Tower Data. *Remote Sensing*, 16(16), 2876. <https://doi.org/10.3390/rs16162876>
- Saggi, M. K., & Jain, S. (2022). A Survey Towards Decision Support System on Smart Irrigation Scheduling Using Machine Learning approaches. *Archives of Computational Methods in Engineering* 29:6, 29(6), 4455–4478. <https://doi.org/10.1007/S11831-022-09746-3>
- Sapkota, R., Meng, Z., & Karkee, M. (2024). Synthetic meets authentic: Leveraging LLM generated datasets for YOLO11 and YOLOv10-based apple detection through machine vision sensors. *Smart Agricultural Technology*, 9, 100614. <https://doi.org/10.1016/j.atech.2024.100614>
- Saranya, T., Deisy, C., Sridevi, S., & Anbananthen, K. S. M. (2023). A comparative study of deep learning and Internet of Things for precision agriculture. *Engineering Applications of Artificial Intelligence*, 122(January 2022), 106034. <https://doi.org/10.1016/j.engappai.2023.106034>
- Singh, H. J., Madane, D. A., Pal, R., & Sharma, R. (2025). Geospatial assessment of paddy crop water requirement using remote sensing and GIS in semiarid Ludhiana area of Indian Punjab. *Theoretical and Applied Climatology*, 156(4), 210. <https://doi.org/10.1007/s00704-025-05434-x>
- Soeb, M. J. A., Jubayer, M. F., Tarin, T. A., Al Mamun, M. R., Ruhad, F. M., Parven, A., Mubarak, N. M., Karri, S. L., & Meftaul, I. M. (2023). Tea leaf disease detection and

- identification based on YOLOv7 (YOLO-T). *Scientific Reports*, 13(1), 1–16. <https://doi.org/10.1038/s41598-023-33270-4>
- Song, Y., Xie, Z., Wang, X., & Zou, Y. (2022). MS-YOLO: Object Detection Based on YOLOv5 Optimized Fusion Millimeter-Wave Radar and Machine Vision. *IEEE Sensors Journal*, 22(15), 15435–15447. <https://doi.org/10.1109/JSEN.2022.3167251>
- Tan, Y. Sen, Chew, L. W., Tan, Y. X., & Tan, S. Z. (2024). IoT-based Smart Farming System. *International Journal of Emerging Multidisciplinaries: Computer Science & Artificial Intelligence*, 3(1). <https://doi.org/10.54938/ijemdc sai.2024.03.1.270>
- Tegegne, D., Schmitter, P., Worqlul, A. W., & Lefore, N. (2025). Estimating crop coefficients for vegetable production and agricultural water management under climate change in sub-humid tropics. *Frontiers in Water*, 7, 1355154. <https://doi.org/10.3389/FRWA.2025.1355154/BIBTEX>
- Thi, P. (2024). IoT Applications in Agriculture: Enhancing Crop Yield in Vietnam. *Asian Journal of Computing and Engineering Technology*, 5(1), 31–40. <https://doi.org/10.47604/ajcet.2809>
- Tian, Y., Ye, Q., & Doermann, D. (2025). YOLOv12: Attention-Centric Real-Time Object Detectors. <http://arxiv.org/abs/2502.12524>
- Tong, Z., Zhang, S., Yu, J., Zhang, X., Wang, B., & Zheng, W. (2023). A Hybrid Prediction Model for CatBoost Tomato Transpiration Rate Based on Feature Extraction. *Agronomy*, 13(9), 2371. <https://doi.org/10.3390/agronomy13092371>
- Tunalı, U., Tüzel, I. H., Tüzel, Y., & Şenol, Y. (2023). Estimation of actual crop evapotranspiration using artificial neural networks in tomato grown in closed soilless culture system. *Agricultural Water Management*, 284(April), 108331. <https://doi.org/10.1016/j.agwat.2023.108331>
- Tunca, E., & Köksal, E. S. (2022). Bell pepper yield estimation using time series unmanned air vehicle multispectral vegetation indexes and canopy volume. *Journal of Applied Remote Sensing*, 16(02), 035001–035007. <https://doi.org/10.1117/1.JRS.16.022202>
- Uygun, T., & Ozguven, M. M. (2024). Determination of tomato leafminer: Tuta absoluta (Meyrick) (Lepidoptera: Gelechiidae) damage on tomato using deep learning instance segmentation method. *European Food Research and Technology*, 1–16. <https://doi.org/10.1007/s00217-024-04516-w>
- Wang, X., & Wang, H. (2023). ACP-YOLO: Asymmetric Center Point Bounding Box Regression Strategy and Angle Loss-based YOLO for Object Detection ACP-YOLO: Asymmetric Center Point Bounding Box Regression Strategy and Angle Loss-based YOLO for Object Detection. 0–10.
- Wang, Y., & Yang, Y. (2024). A Novel Secure and Energy-efficient Routing Method for the Agricultural Internet of Things Using Whale Optimization Algorithm. *Journal of Cyber Security and Mobility*, 13(4), 725–750. <https://doi.org/10.13052/jcsm2245-1439.1347>
- Wei, J., Ni, L., Luo, L., Chen, M., You, M., Sun, Y., & Hu, T. (2024). GFS-YOLO11: A Maturity Detection Model for Multi-Variety Tomato. *Agronomy*, 14(11), 2644. <https://doi.org/10.3390/agronomy14112644>
- Woldemariam, G. W., Awoke, B. G., & Maretto, R. V. (2025). Satellite-Based energy balance for estimating actual sugarcane evapotranspiration in the Ethiopian Rift Valley. *ISPRS Journal of Photogrammetry and Remote Sensing*, 223, 109–130. <https://doi.org/10.1016/j.isprsjprs.2025.03.003>

- Workneh, A. C., Prasad, K. S. H., & Ojha, C. S. P. (2025). Comparison of the Self-Organizing Map and the Adaptive Neuro-Fuzzy Inference System in Predicting the Paddy Crop Water Stress Index. *Journal of Irrigation and Drainage Engineering*, 151(1), 04024040. <https://doi.org/10.1061/JIDEDH.IRENG-10171>
- Wu, Y., Han, Q., Jin, Q., Li, J., & Zhang, Y. (2023). LCA-YOLOv8-Seg: An Improved Lightweight YOLOv8-Seg for Real-Time Pixel-Level Crack Detection of Dams and Bridges. *Applied Sciences (Switzerland)*, 13(19), 10583. <https://doi.org/10.3390/app131910583>
- Xu, C., Hu, X., Tian, J., Guo, X., & Lei, J. (2025a). Estimating the Grape Basal Crop Coefficient in the Subhumid Region of Northwest China Based on Multispectral Remote Sensing by Unmanned Aerial Vehicle. *Horticulturae*, 11(2), 217. <https://doi.org/10.3390/horticulturae11020217>
- Xu, C., Hu, X., Tian, J., Guo, X., & Lei, J. (2025b). Estimating the Grape Basal Crop Coefficient in the Subhumid Region of Northwest China Based on Multispectral Remote Sensing by Unmanned Aerial Vehicle. *Horticulturae*, 11(2), 217. <https://doi.org/10.3390/horticulturae11020217>
- Younes, A., Ellassad, Z. E. A., Meslouhi, O. El, Ellassad, D. E. A., & Abdel Majid, E. dahbi. (2024). The application of machine learning techniques for smart irrigation systems: A systematic literature review. *Smart Agricultural Technology*, 7, 100425. <https://doi.org/10.1016/j.atech.2024.100425>
- Yue, X., Qi, K., Na, X., Zhang, Y., Liu, Y., & Liu, C. (2023). Improved YOLOv8-Seg Network for Instance Segmentation of Healthy and Diseased Tomato Plants in the Growth Stage. *Agriculture (Switzerland)*, 13(8), 1643. <https://doi.org/10.3390/agriculture13081643>
- Zeleeke, K., & Nendel, C. (2024). Yield response and water productivity of soybean (*Glycine max* L.) to deficit irrigation and sowing time in south-eastern Australia. *Agricultural Water Management*, 296, 108815. <https://doi.org/10.1016/j.agwat.2024.108815>
- Zeyliger, A. M., & Ermolaeva, O. S. (2021). Water stress regime of irrigated crops based on remote sensing and ground-based data. *Agronomy*, 11(6), 1117. <https://doi.org/10.3390/agronomy11061117>
- Zhai, X., Huang, Z., Li, T., Liu, H., & Wang, S. (2023). YOLO-Drone: An Optimized YOLOv8 Network for Tiny UAV Object Detection. *Electronics (Switzerland)*, 12(17), 3664. <https://doi.org/10.3390/electronics12173664>
- Zhang, B., Liu, Y., Xu, D., Zhao, N., Lei, B., Rosa, R. D., Paredes, P., Paço, T. A., & Pereira, L. S. (2013). The dual crop coefficient approach to estimate and partitioning evapotranspiration of the winter wheat–summer maize crop sequence in North China Plain. *Irrigation Science*, 31(6), 1303–1316. <https://doi.org/10.1007/s00271-013-0405-1>
- Zhang, C., Yang, H., Wu, W., & Li, W. (2017). Effect of drought stress on physiological changes and leaf surface morphology in the blackberry. *Brazilian Journal of Botany*, 40(3), 625–634. <https://doi.org/10.1007/s40415-017-0377-0>
- Zhang, H., Manh, L. H., Ha, D. H., Andales, A., & Wang, S. (2025). Prototype web-based platform for the calculation of crop water stress index for irrigation scheduling – An application note. *Computers and Electronics in Agriculture*, 230, 109870. <https://doi.org/10.1016/j.compag.2024.109870>
- Zhang, Y., Wang, X., Jin, L., Ni, J., Zhu, Y., Cao, W., & Jiang, X. (2025). Research and Development of an IoT Smart Irrigation System for Farmland Based on LoRa and

Edge Computing. *Agronomy*, 15(2), 366. <https://doi.org/10.3390/agronomy15020366>

Zhong, J., Chen, J., & Mian, A. (2023). DualConv: Dual Convolutional Kernels for Lightweight Deep Neural Networks. *IEEE Transactions on Neural Networks and Learning Systems*, 34(11), 9528–9535. <https://doi.org/10.1109/TNNLS.2022.3151138>



ÖZGEÇMİŞ

Kişisel Bilgiler	
Adı Soyadı:	Ahmet ÖZMEN
Doğum tarihi:	
Doğum Yeri:	
Uyruğu:	
Adres:	
E-mail:	
Eğitim	
Lisans:	Atatürk Üniversitesi, Elektrik-Elektronik Mühendisliği
Yüksek lisans:	Atatürk Üniversitesi, Nanobilim ve Nano Mühendisliği Anabilim Dalı (2018)
	Atatürk Üniversitesi, Elektrik-Elektronik Mühendisliği Anabilim Dalı (2022)
Doktora:	Atatürk Üniversitesi, Elektrik-Elektronik Mühendisliği Anabilim Dalı (2025)
Yabancı Dil Bilgisi	
İngilizce:	İyi
Üye Olunan Mesleki Kuruluşlar	
Elektrik Mühendisleri Odası	
Tezden Üretilmiş Yayınlar-Makale	
Tezden Üretilmiş Yayınlar-Bildiri	
❖ Özmen, A., & Ertugrul, M. (2024). Comparative Analysis of Database Technologies for IoT Environments. 7th International Conference on Advances in Natural and Applied Sciences (ICANAS 2024), Antalya.	
Tezden Üretilmiş Yayınlar-Patent	
Tarım Uygulamaları İçin Görüntü İşleme ve Yapay Zeka Destekli Sulama Yönetim Sistemi - TR 2024/017981-inceleme aşaması	
Tez Dışı Yayınlar - Makale	
❖ Özmen, A., Coşkun, A., & Ertugrul, M. (2025). Design and Fabrication of Multi-Magnetron Microwave Oven for High-Temperature Applications. Turkish Journal of Engineering, 9(1), 95-102.	
❖ Karaboga, F., Farhangmehr, M., Özmen, A., Yetis, H., Belenli, I., & Ertugrul, M. (2024). Investigation of hybrid wires combining superconductive MgB2 and ultra-conductive Graphene/Cu sheath. Journal of Alloys and Compounds, 973, 172907.	
❖ Tursucu, A., Aydogan, S., Kocyigit, A., Ozmen, A., & Yilmaz, M. (2022). Investigation the performance of Cr-doped ZnO nanocrystalline thin film in photodiode applications. Jom, 74(3), 777-786.	
❖ Coskun, A., Hasar, U. C., Ozmen, A., & Ertugrul, M. (2022). Easy-to-Implement Ultra-Thin, Wide-Band, and Multi-Functional Polarization Converter for K and Ka Band Applications. Advanced Theory and Simulations, 5(4), 2100543.	
❖ Özmen, A., Mobtakeri, S., Koçak, Y., Akbaba, U., Ertugrul, M., & Gür, E. (2021). Ultra-conductive wires with cascaded carbon nanotube/Cu structure. Diamond and Related Materials, 120, 108711.	

❖ Turgut, G., Aydogan, S., Yilmaz, M., Özmen, A., & Kacus, H. (2021). An Investigation of Spray Deposited CdO Films and CdO/p-Si Heterojunction at Different Substrate Temperatures. JOM, 73, 1210-1210. ❖ Özmen, A., Aydogan, S., & Yilmaz, M. (2019). Fabrication of spray derived nanostructured n-ZnO/p-Si heterojunction diode and investigation of its response to dark and light. Ceramics International, 45(12), 14794-14805. ❖ Habashyani, S., Özmen, A., Aydogan, S., & Yilmaz, M. (2018). An examination of correlation between characteristic and device performance of ZnO films as a function of La content. Vacuum, 157, 497-507.
Tez Dışı Yayınlar - Patent
❖ Industrial Microwave Metal Melting Oven-CT/TR2023/050754 -WO2025029201A1 ❖ Automatic Fraction Collection Device - TR2022/021633 - WO2024144484A1 ❖ CNT-Metal (Al, Cu, vd.) Ultra-Conductive Composite Wires and a Method and System for Ultra-Conductive Wire Production - TR2021/050820 - WO2022071901A1 ❖ Method And System for Production of Layered Cu-Graphene Ultra Conductor Wire - TR202016383A1 - WO2022081113A1 - US2023054260A1
Tez Dışı Yayınlar - Bildiri
❖ Karaboğa, F., Farhangmehr, M., Özmen, A., Yetiş, H., Belenli, İ., & Ertuğrul, M. (2023). Investigation and Production of Hybrid Wires Combining Superconductive MgB2 and Ultra-conductive Graphene Cu sheath. Presented at the International Conference on Sensor, Detector, Materials Science and Technologies (SensTech-2023) . ❖ Özmen, A., & Ertugrul, M. (2022). Waveguide Design and Application for Multi-Magnetron Microwave Oven. 6th International Conference on Advances in Natural and Applied Sciences (ICANAS-22) ❖ Coşkun, A., Özmen, A., Aksoy, M. A., & Ertuğrul, M. (2018). Fabrication of YBCO Metamaterials by Screen Printing Method. Presented at the ISASE2018, Erzurum. ❖ Koçak, Y., Özmen, A., Ertuğrul, M., & Gür, E. (2017). CuO nanoparticle composite structures with carbonnanotubes. Presented at the Trends in Nanotechnology (TNT 2017) . ❖ Coşkun, A., Özmen, A., Aksoy, M. A., Geyikoğlu, M. D., & Ertuğrul, M. (2017). Improving The Performance of Ybco Superconducting Microwave Resonator. Presented at the International Conference on Condensed Matter and Materials Science-2017 (iccmms-17), Adana. ❖ Koçak, Y., Özmen, A., Gür, E., & Ertuğrul, M. (2017). Cu MWCNT Kompozit Malzemesinin Yapısal Karakterizasyonu. Presented at the International Conference on Advanced Engineering Technologies (ICADET2017), Bayburt. ❖ Yeşilbağ, Y. Ö., Aktürk Önbalaban, E., Tuzluca Yeşilbağ, F. N., Özmen, A., & Ertuğrul, M. (2017). H2 Gas Sensing Properties Of Cuo Nanowires Grown On Copper Foam. Presented at the 13th Nanoscience and Nanotechnology Conference (NANOTR-13) ❖ Özmen, A., Coşkun, A., Aksoy, M. A., Geyikoğlu, M. D., & ERTUĞRUL, M. (2017). Ybco Metamaterials Fabricated By Screen Printing Method. Presented at the International Conference On Condensed Matter And Materials Science-2017 (iccmms-17), Adana. ❖ Aksoy, M. A., Özmen, A., Coşkun, A., Geyikoğlu, M. D., & Ertuğrul, M. (2017). Shielding Effectiveness Analysis of Transparent Oxide Coated Glass. Presented at the International Conference on Condensed Matter And Materials Science-2017 (iccmms-17), Adana.