



TARIM VE HAYVANCILIKTA DİJİTAL DÖNÜŞÜM

EDİTÖR:
İSMAİL ÜLGER



BİDGE Yayınları

Tarım ve Hayvancılıkta Dijital Dönüşüm

Editör: İSMAİL ÜLGER

ISBN: 978-625-8989-84-7

1. Baskı

Sayfa Düzeni: Gözde YÜCEL

Yayınlama Tarihi: 2026-06-25

BİDGE Yayınları

Bu eserin bütün hakları saklıdır. Kaynak gösterilerek tanıtım için yapılacak kısa alıntılar dışında yayıncının ve editörün yazılı izni olmaksızın hiçbir yolla çoğaltılamaz.

Sertifika No: 71374

Yayın hakları © BİDGE Yayınları

www.bidgeyayinlari.com.tr - bidgeyayinlari@gmail.com

Krc Bilişim Ticaret ve Organizasyon Ltd. Şti.

Güzeltepe Mahallesi Abidin Daver Sokak Sefer Apartmanı No: 7/9 Çankaya /
Ankara



ÖNSÖZ

Dünya nüfusundaki hızlı artış, iklim değişikliği, doğal kaynakların sınırlılığı ve gıda güvenliği konusundaki endişeler, tarım ve hayvancılık sektöründe köklü bir dönüşümü zorunlu kılmaktadır. Geleneksel yöntemlerin yerini giderek daha fazla veri temelli, akıllı ve sürdürülebilir üretim sistemleri almaktadır. Bu dönüşümün merkezinde ise dijital teknolojiler, büyük veri analitiği, sensör teknolojileri, robotik sistemler ve yapay zekâ uygulamaları yer almaktadır.

Tarım ve hayvancılıkta dijital dönüşüm, yalnızca süreçlerin otomasyonu anlamına gelmemekte; aynı zamanda kaynak kullanım etkinliğinin artırılması, maliyetlerin azaltılması, hayvan refahının iyileştirilmesi, çevresel etkilerin en aza indirilmesi ve sürdürülebilirlik hedeflerine ulaşılması açısından da stratejik bir önem taşımaktadır. Hassas tarım ve hassas hayvancılık yaklaşımları sayesinde üreticiler, gerçek zamanlı veriler ışığında daha doğru, hızlı ve etkin kararlar alabilmekte; böylece hem ekonomik hem de ekolojik denge desteklenmektedir.

Bu kitap, tarım ve hayvancılık sektöründe yaşanan dijital dönüşümü farklı boyutlarıyla ele almayı amaçlamaktadır. Kitap kapsamında; kanatlı yetiştiriciliğinde dijitalleşme ve yapay zekâ uygulamalarından sığırcılıkta hassas hayvancılık sistemlerine, sürdürülebilir tarım ilkelerinden geleceğin üretim stratejilerine kadar geniş bir perspektif sunulmaktadır. Alanında uzman araştırmacılar tarafından hazırlanan bölümler, güncel bilimsel gelişmeleri, uygulama örneklerini ve geleceğe yönelik öngörülerini bir araya getirerek okuyuculara kapsamlı bir kaynak oluşturmayı hedeflemektedir.

Bu eserin; akademisyenlere, araştırmacılara, lisansüstü öğrencilere, sektör paydaşlarına ve üreticilere yararlı olacağı düşünülmektedir. Dijital teknolojilerin yaygınlaştırılmasına, sürdürülebilir üretim anlayışının geliştirilmesine ve geleceğin akıllı üretim sistemlerinin şekillendirilmesine katkı sağlaması en büyük temennimizdir.

Kitabın hazırlanmasında emeği geçen tüm bölüm yazarlarına, bilimsel bilgi ve deneyimlerini paylaşarak eserin ortaya çıkmasına katkı sağlayan araştırmacılara ve yayın sürecinde destek veren herkese teşekkür ederiz.

Bilim ve teknolojinin ışığında, daha verimli, daha sürdürülebilir ve daha dirençli bir tarım ve hayvancılık sistemi oluşturulmasına katkı sunması dileğiyle...

Prof. Dr. İsmail ÜLGER

İÇİNDEKİLER

KANATLI HAYVANLARDA DİJİTALLEŞME VE YAPAY ZEKÂ ENTEGRASYONUN ÖNEMİ	1
--	---

İRFAN İNAN, MEHMET SALİH KAÇMAZ, SAVAŞ DEMİR

HASSAS HAYVANCILIKTA SIĞIRLARDA YAPAY ZEKÂ UYGULAMALARI	26
---	----

İRFAN İNAN, MEHMET SALİH KAÇMAZ, SAVAŞ DEMİR

SÜRDÜRÜLEBİLİR TARIM SİSTEMLERİ: İLKELER ETKİLER ZORLUKLAR FIRSATLAR VE GELECEK STRATEJİLERİ	55
--	----

İRFAN İNAN, MEHMET SALİH KAÇMAZ, SAVAŞ DEMİR

VARYANS ANALİZLERİNDE EKSİK VERİ DOLDURMA YÖNTEMLERİ VE MODERN YAKLAŞIMLAR	77
--	----

HAMZA YALÇIN

BÖLÜM 1

KANATLI HAYVANLARDA DİJİTALLEŞME VE YAPAY ZEKÂ ENTEGRASYONUN ÖNEMİ

İrfan İNAN¹

Mehmet Salih KAÇMAZ²

Savaş DEMİR³

1.GİRİŞ

Küresel ölçekte iklim değişikliği, ekonomik krizler ve artan gıda talebi; tarımsal üretim sistemlerinin istikrarı açısından önemli zorluklar oluşturmaktadır.Nüfus artışının hızlanmasıyla birlikte küresel ölçekte yumurta ve kanatlı eti talebinin önemli ölçüde artması beklenmektedir (Abdelrahman ve ark., 2026; Morsi ve ark., 2025).

Küresel kanatlı sektörüne olan talebi karşılamak amacıyla tavuk yetiştiriciliğinin ölçeği büyümeye devam ettikçe; daha yüksek üretim çıktısını, daha iyi refah koşullarını ve daha düşük çevresel ayak izini eş zamanlı sağlayabilecek yenilikçi teknolojilere olan

¹ Yüksek Ziraat Mühendisi, Van Yüzüncü Yıl Üniversitesi, Hayvan Yetiştirme ve Islahı Anabilim Dalı, Van, Türkiye, Orcid: 0009-0007-0084-1394

² Arş. Gör. Dr., Van Yüzüncü Yıl Üniversitesi, Yemler ve Hayvan Besleme Anabilim Dalı, Van, Türkiye, Orcid: 0000-0003-3419-7342

³ Dr., Van Yüzüncü Yıl Üniversitesi, Tıbbi ve Aromatik Bitkiler Anabilim Dalı, Van, Türkiye, Orcid ID: 0000-0002-3795-8883

ihtiyaç giderek daha kritik hâle gelmektedir (Brassó ve ark., 2025; Kaswan ve ark., 2024).

Küresel kanatlı sektörü, artan hayvansal protein talebini karşılamakla yükümlü kritik bir üretim alanıdır. Kanatlı yetiştiriciliği, küresel tarım sisteminin önemli bir bileşeni olup et ve yumurta üretimine büyük katkı sağlamaktadır. Tavuk eti ve yumurta, en erişilebilir ve küresel ölçekte en fazla değer gören gıdalar arasında yer almakta olup bu durum sürekli yüksek talep oluşmasına neden olmaktadır. Kanatlı sektörü, artan küresel talebi karşılamak amacıyla yüksek kaliteli protein sunarak gıda güvenliğine önemli katkı sağlamaktadır (Abbas ve ark., 2025; Engelbrecht ve ark., 2026; Franzo ve ark., 2023; Olanrewaju ve ark., 2024; Usturoi ve ark., 2025).

Büyüme ve verimlilik düzeyine rağmen sektör; üretkenliğin artırılması, kaynak kullanımının optimize edilmesi ve hayvan refahının güvence altına alınması gibi önemli zorluklarla karşı karşıyadır. Kanatlı üretiminin geleceği, öznel ve iş gücü yoğun refah değerlendirme yöntemlerinden veri temelli ve akıllı izleme sistemlerine geçişi gerektiren devrim niteliğinde bir paradigma değişimine bağlıdır (Engelbrecht ve ark., 2026; Essien & Neethirajan, 2025).

Hassas hayvancılık uygulamalarının gelişimiyle birlikte üretim süreçleri daha sistematik ve ölçülebilir hâle gelmiş; sensör ve veri tabanlı yaklaşımlar sayesinde yönetim kararları optimize edilmiştir. Kanatlı yetiştiriciliğinde yapay zekâ uygulamaları; daha verimli, veri odaklı ve sürdürülebilir hayvancılık yönetimine doğru önemli bir adımı temsil etmektedir. Yapay zekâ, geleneksel tavuk yetiştiriciliği modellerini temelden dönüştürecek bir güç olarak yaygın biçimde kabul edilmektedir. İş gücü maliyetlerini azaltırken hayvan refahını güvence altına alabilmekte, aynı zamanda üretim miktarı ve ürün kalitesini artırabilmektedir (Fan ve ark., 2025; Roy & Rana, 2025; Wu ve ark., 2025).

Yapay zekâ, makine öğrenmesi ve Nesnelerin İnterneti alanlarındaki hızlı gelişmeler, hassas yönetim ve gerçek zamanlı karar alma olanakları sağlayarak modern kanatlı yetiştiriciliğini dönüştürmüştür. Yapay zekâ ayrıca kaynak tahsisini kolaylaştırmakta, iş gücü maliyetlerini azaltmakta ve ürün kalitesinde tutarlılık sağlamaktadır. Bu durum özellikle transformatör tabanlı modellerle sürü sayımı ve karkas hacmi derecelendirme uygulamalarında gösterilmiştir. Entegre veri akışları sayesinde üreticiler; hastalık önleme, refah iyileştirme ve kaynak kullanım optimizasyonunu eş zamanlı olarak ele alan stratejiler geliştirebilmektedir (Franzo ve ark., 2023; Natsir ve ark., 2025; Odili ve ark., 2024).

Yapay zekâ ile hayvan refahı biliminin kesişimi, tarımsal üretim tarihinde kritik bir dönüm noktasında bulunmaktadır. Çok modlu yapay zekâ sistemleri yalnızca teknolojik bir ilerlemeyi değil; ticari üretim koşullarında yumurta tavuklarının yaşamını anlama, izleme ve iyileştirme biçimimizin temelden yeniden kurgulanmasını temsil etmektedir. Genel olarak, kanatlı yetiştiriciliğinde yapay zekâ ve robotik kullanımının; erken hastalık tespiti, çevresel koşulların iyileştirilmesi, yem formülasyonunun optimize edilmesi ve otomasyon düzeyinin artırılması gibi çok yönlü faydalar sunduğunu ortaya koymaktadır (Essien & Neethirajan, 2025; Taleb ve ark., 2025).

Bu derleme çalışmasının amacı, kanatlı hayvan yetiştiriciliğinde dijitalleşme ve yapay zekâ entegrasyonunun uygulama alanlarını incelemek; literatürde kanatlı hayvanlar üzerine yürütülen güncel çalışmaların bulgularını değerlendirerek, kullanılan yapay zekâ destekli teknolojilerin üretim verimliliği, hayvan refahı ve sürdürülebilirlik üzerindeki etkilerini ortaya koymaktır.

2. Kanatlı Hayvanlarda Yapay Zeka Entegrasyonunun Önemi ve Avantajları

Hassas kanatlı yetiştiriciliği, kanatlı üretim operasyonlarının dünya genelinde yönetilme biçiminde dönüştürücü bir değişimi temsil etmektedir. Yapay zekâ, bilgisayarlı görme, makine öğrenmesi, derin öğrenme, Nesnelerin İnterneti, uç bilişim, robotik sistemler ve veri analitiği teknolojilerinden yararlanarak; üretkenliği, sürdürülebilirliği ve hayvan refahını artıran gerçek zamanlı ve kanıta dayalı karar alma süreçlerini mümkün kılmaktadır. Kenar yapay zekâ çözümleri ise gecikmeyi azaltmakta ve bulut bilişime bağımlılığı düşürerek düşük bağlantı altyapısına sahip işletmelerde yerinde izleme uygulamalarını mümkün kılmaktadır (Natsir ve ark., 2025; Paneru ve ark., 2026).

Hassas hayvancılıkta özellikle öğrenme ve algılama temelli yapay zekâ alanlarında çok çeşitli tekniklerin kullanıldığını ortaya koymaktadır. Bu tekniklerin; hayvan tanıma, anormallik tespiti ile sağlık ve refah izleme gibi görevlerde etkili olduğu belirlenmiştir. Bununla birlikte, çevresel izleme ve sürdürülebilirlik odaklı uygulamalara görece daha az yer verildiği görülmüş olup bu durum gelecekte daha fazla araştırılması gereken önemli bir boşluk alanına işaret etmektedir. Elde edilen bulgular, yapay zekâ teknolojilerinin benimsenmesinin yalnızca kanatlı işletmelerinin ekonomik sürdürülebilirliğine katkı sağlamakla kalmayıp aynı zamanda etik standartlar ve sürdürülebilirlik hedefleriyle de uyumlu olduğunu göstermektedir. Bu durum, kanatlı sektörünün geleceği açısından umut verici bir yönelim ortaya koymaktadır (Distant ve ark., 2025; Engelbrecht ve ark., 2026).

Tablo 1. Hassas Kanatlı Yetiştiriciliğinde Yapay Zekâ Entegrasyonlu Tespit Teknolojilerinin Karşılaştırılması

Teknoloji	Temel Avantajlar	Yaygın Uygulamalar	Başlıca Zorluklar	Olası Çözüm Yaklaşımları
Bilgisayarlı Görme	Temassız izleme olanağı; hassas davranış tanıma	Davranış analizi; erken hastalık uyarısı; sürü yoğunluğu değerlendirmesi	Değişken aydınlatma etkisi; örtüşme (oklüzyon) sorunları; model genellenebilirliğinin zayıf olması	Çok spektralli görüntüleme; transfer öğrenme; açık erişimli veri setleri
Kızılötesi Termografi)	Tüy altı Vücut sıcaklığının ölçülebilmesi; semptom öncesi uyarı kapasitesi	Vücut sıcaklığı izleme; ateşli hastalık tespiti; stres yanıtı değerlendirme	Çevresel koşullardan etkilenme; ölçüm doğruluğunda değişkenlik	Çoklu sensör füzyonu; kompakt donanım tasarımı; tüysüz bölgelerin hedeflenmesi
Radio Frekans ile Tanımlama (RFID)	Bireysel hayvan takibi; uzun süreli sürekli izleme	Yem ve su tüketimi ölçümü; yetiştirme performansı değerlendirme	Metal parazitlenmesi; sinyal çakışması; konum doğruluğunun sınırlı olması	Ultra geniş bant konumlama teknolojisi; metal dirençli etiket

Teknoloji	Temel Avantajlar	Yaygın Uygulamalar	Başlıca Zorluklar	Olası Çözüm Yaklaşımları
				tasarımı; bilgisayarlı görme ile eş kalibrasyon
Akustik Analiz)	Düşük maliyetli gerçek zamanlı izleme; invaziv olmayan solunum takibi	Öksürük ve hapsirik tespiti; stres yanıtı analizi; fertilitate taraması	Çevresel gürültü kirliliği; dinamik akustik imza değişimleri	Uyarlanabilir gürültü bastırma algoritmaları; türe özgü akustik imza veri tabanları

Kaynak: Fan ve ark., 2025

Algılama cihazlarının akıllı teknolojiler, derin öğrenme algoritmaları ve robotik sistemlerle artan entegrasyonu, makine öğrenmesindeki gelişmelerle birlikte gerçek dünyadaki bir varlığın dijital kopyası olan Dijital İkiz (Digital Twin) teknolojisini destekleyerek modern hayvancılık biliminde dönüştürücü bir sinerji oluşturmuştur; giriş verilerine dayalı olarak hayvanların fizyolojik ve fiziksel durumları ile davranışlarını taklit edebildiği gösterilmiştir. Bu durum, hayvan davranışlarının, beslenme gereksinimlerinin, fizyolojik durumlarının ve çevresel stres faktörlerinin daha iyi anlaşılmasını sağlamakta; verilen tepkilerin analiz edilmesine ve hassas karar önerilerinin geliştirilmesine imkân tanımaktadır (Abdelrahman ve ark., 2026; Losacco ve ark., 2025).

Tablo2. Kanatlı üretiminde yapay zekâ, bilgisayarlı görme ve sensör tabanlı sistemlerin uygulama alanlarına ilişkin Çalışmalar

Uygulama / Model / Sensör / Platform / Temel Katkı	Görev	Yöntem	Veri	Sistem	Kaynaklar
Broiler tavuklarda <i>kinky back</i> (iskelet deformitesi) tespiti	Optimize edilmiş derin öğrenme modelleri	RGB görüntü verisi	Görüntü tabanlı denetim sistemi	Refah ve yönetimi iyileştirmek için iskelet deformitelerini otomatik tespit eden sistem geliştirilmesi	Bist et al., 2025
Avian influenza önleme için yabani kuş izleme	Makine görüşü ve nesne tespiti	Kamera görüntü verisi	Çiftlik içi izleme sistemi	Kümeslerde yabani kuş tespiti ile biyogüvenlik artırımı	Yang et al., 2024
Otomatik kanatlı sayımı ve hareket takibi	Bilgisayarlı görme ve algoritmaları	Video ve görüntü verisi	Otomatik sayım ve izleme sistemi	Gerçek zamanlı sürü sayımı ve hareket analizi için düşük maliyetli sistem tasarımı	Cruz et al., 2025
Broiler tartım yöntemlerini	İstatistiksel ve karşılaştırma	Canlı ağırlık ölçüm verileri	Ticari broiler kümesleri	Farklı tartım yöntemlerini verimlilik ve	Pasian et al., 2025

Uygulama / Model / Sensör / Platform / Temel Katkı	Görev	Yöntem	Veri	Sistem	Kaynaklar
değerlendiril mesi	malı analiz			(askılı platform sistemleri)	güvenilirlik açısından karşılaştırılması
Kanatlı yetiştiriciliği için robotik yapı tasarımı	Mekanik tasarım ve prototipleme	Sensör entegre bileşenler	Robotik platform	Otomasyon ve iş gücü verimliliğini artırmaya yönelik robot tasarımı	Da Rocha Balthazar et al., 2025
Broiler kümeslerindeki çevre değerlendir mesi	Çevresel izleme ve analiz	Sıcaklık ve çevresel sensörler	Prototip broiler kümesleri	Yeşil çatı uygulamasının termal çevre, enerji ve refah üzerindeki etkilerinin değerlendiril mesi	De Souza et al., 2025
Stok yoğunluğunun broilerin refahına etkisi	Deneyssel ve istatistiksel analiz	Performans ve refah göstergeleri	Ticari broiler üretim sistemleri	Stok yoğunluğunun refah ve performans üzerindeki etkisinin kanıta dayalı analizi	Zhou et al., 2024

Tavuk yetiřtiriciliğinde yapay zekâ uygulamaları; daha verimli, veri odaklı ve sürdürülebilir hayvancılık yönetimine doğru önemli bir adımı temsil etmektedir. Hassas hayvancılık uygulamalarının gelişimiyle birlikte üretim süreçleri daha sistematik ve ölçülebilir hâle gelmiş; sensör ve veri tabanlı yaklaşımlar sayesinde yönetim kararları optimize edilmiştir. Görüntü, sensör ve üretim verilerinin entegre edilmesi; izleme süreçlerinin otomatikleştirilmesini, üretimin optimize edilmesini ve hayvan sağlığı ile refahının daha etkin biçimde korunmasını mümkün kılmaktadır (Bretas ve ark., 2024; Hsieh ve ark., 2025; Roy & Rana, 2025).

Modern kanatlı yetiřtiriciliği sistemlerinde bilgisayarlı görme, kızılötesi termografi, radyo frekansı ile tanımlama ve ses analiz teknolojilerinin uygulamalarına odaklanmaktadır. Çoklu teknoloji entegrasyonu; kanatlı davranışlarının izlenmesi, erken dönem hastalıkların tespiti, semen kalitesinin değerlendirilmesi, yumurta kalitesinin analiz edilmesi ve yetiřtirme ortamlarının düzenlenmesi gibi temel alanlarda önemli bir potansiyel göstermektedir (Fan ve ark., 2025). Yapay zekâ destekli iklim kontrolü ve hassas yemleme sistemleri; kaynak kullanımını optimize etmekte, enerji tüketimini azaltmakta ve çevresel emisyonları en aza indirmektedir. Otomasyon ve robotik uygulamalar; iş gücüne bağımlılığı azaltmakta, biyogüvenliği iyileřtirmekte ve yumurta toplama ile tesis izleme gibi görevlerde süreç tutarlılığını artırmaktadır (Paneru ve ark., 2026).

Elde edilen bulgulara göre: yapay zekânın sürdürülebilirliğe katkısı değerlendirilmiştir.

Refah boyutunda, yapay zekâ uygulamaları ağırlıklı olarak hastalık gözetimi, davranış izleme, stres tespiti ve sağlık puanlamasına odaklanmakta; daha erken ve daha az invaziv müdahalelere olanak tanımakta, daha istikrarlı ve daha uzun üretken yaşam süreleri sağlamaktadır.

Ekonomik boyutta, otomatik sayım sistemleri, görme tabanlı canlı ağırlık tahmini ve hassas besleme uygulamaları; iş gücü verimliliğini ve yem kullanım etkinliğini artırırken ürün kalitesini de iyileştirmektedir.

Çevresel boyutta, yapay zekâ; koku tahmini, havalandırma izleme ve kontrol stratejilerini destekleyerek emisyonları ve enerji tüketimini azaltmakta, böylece işletmelerin çevresel ayak izini küçültmektedir. (Wu ve ark., 2025).

3. Kanatlı Hayvanlarda Yapay Zeka Entegrasyonunda Literatürde Yapılan Çalışmalar

Yapay zekâ ve biyoakustik alanındaki gelişmeler, gelişmiş vokalizasyon analizi yoluyla kanatlı refahının invazif olmayan biçimde izlenmesinde önemli bir paradigma değişimi yaratmaktadır (Manikandan ve Neethirajan, 2025).Yapay zekâ, hayvanların duygusal durumlarını yorumlama ve bu durumlara yanıt verme kapasitemizde devrim niteliğinde gelişmeler sağlamaktadır. Çalışmada, akut çevresel strese maruz kalan yumurtacı tavukların karmaşık vokalizasyon örüntülerini çözümlemek amacıyla Mel Frekans Kepstral Katsayıları ile birleştirilmiş gelişmiş Evrişimsel Sinir Ağları kullanılmaktadır (Neethirajan, 2025).

Küresel ölçekte hayvan refahı ve gıda güvenliğine yönelik artan hassasiyet, kanatlı endüstrisinde insancıl ve verimli kesim yöntemlerine olan talebi artırmaktadır. Etlik piliçlerin elektriksel sersemletilmesine yönelik geleneksel manuel denetim yöntemleri yüksek uzmanlık gerektirmektedir. Yapılan çalışmada sistem, kesim sürecine entegre edilmiş Nesnelerin İnterneti destekli bir görsel izleme altyapısı ile gerçek zamanlı sersemletme izleme ve akıllı yönetim sağlamaktadır (Lin ve Suhendra, 2025).

Küresel kanatlı üretimindeki üstel büyüme, etkin sürü yönetimine duyulan kritik gereksinimi ortaya koymakta; özellikle tavukların doğru şekilde sayılması, operasyonların optimize

edilmesi ve ekonomik kayıpların en aza indirilmesi açısından büyük önem taşımaktadır (Cruz ve ark., 2024).

Grup hâlinde barındırılan bireysel etlik piliçlerin video aracılığıyla izlenmesi; hayvan sağlığı, refahı ve performansı hakkında değerli bilgiler sağlayarak yetiştiricilerin genetik iyileştirmeye katkı sunacak yeni veya gösterge özellikleri belirlemesine olanak tanımaktadır (Doornweerd ve ark., 2024).

Etlik piliç davranışlarında hayvan sağlığı ve refahı ile ilişkili değişimleri izlemek amacıyla yetiştiriciler sürülerini genellikle manuel gözlem yoluyla takip etmektedir. Ancak bu sürecin emek yoğun ve sürekli izleme gerektiren bir yapıya sahip olması nedeniyle, etlik piliç davranış analizinin kamera teknolojileri kullanılarak otomatikleştirilmesi mümkündür. Bilgisayarlı görüş sistemlerinin çiftlik içi olaylarla ilişkili kısa süreli ve belirgin aktivite değişimlerini izleme potansiyelini ortaya koymakta; ayrıca teknolojinin hayvan refahı durumundaki uzun vadeli değişimlerin izlenmesinde kullanılmasına yönelik fırsatları tartışmaktadır (Campbell ve ark., 2024).

Vücut sıcaklığı, yumurtacı tavukların ve diğer evcil hayvanların sağlık ve verimlilik durumunun kritik bir göstergesidir. Termografi alanındaki son gelişmeler, hayvanlarla fiziksel temas gerektirmeden yüzey sıcaklığının hassas biçimde ölçülmesine olanak tanımakta ve insan teması kaynaklı stresin azaltılmasını sağlamaktadır (Saeidifar ve ark., 2024).

Etlik piliç işletmelerinde erken dönem stresin tespit edilmesi, büyüme performansının optimize edilmesi ve hayvan refahının korunması açısından kritik öneme sahiptir. Soğuk, sıcak veya rüzgâra maruz bırakılan etlik piliçlerde ortaya çıkan farklı stres çağrılarının, akustik sinyal işleme teknikleri ve Transformer tabanlı yapay sinir ağı kullanılarak sınıflandırılması çalışması yapılmaktadır (Lev-Ron ve ark., 2025).

Ticari kanatlı yetiştiriciliğinde bireysel etlik piliçlerin etkin ve kesintisiz biçimde izlenmesi; yönetim uygulamalarının iyileştirilmesi, hayvan refahının artırılması ve damızlık seçimine yönelik kararların geliştirilmesi açısından kritik öneme sahiptir. Ancak standart Çoklu Nesne İzleme teknikleri, örtüşmelerin yoğun olması, nesneler arası benzerliğin yüksekliği ve sürü yoğunluğunun fazla olması nedeniyle kanatlı yetiştiriciliği ortamlarında önemli zorluklarla karşılaşmaktadır. Kanatlı endüstrisine özgü olarak tasarlanmış, çok kameralı ve çoklu etlik piliç izlemeye yönelik yeni bir çerçeve olan BroilerTrack çalışması yapılmaktadır (Phan ve ark., 2025).

Etlik piliçlerin su içme davranışının incelenmesi, yetiştiricilere hayvan refahı hakkında önemli bilgiler sağlamakta; ayrıca çiftlik yönetimi ve kanatlı yetiştiriciliğinde optimum koşulların oluşturulmasına yönelik değerli içgörüler sunmaktadır. Davranış tanımaya dayalı üç aşamalı bir algoritma kullanarak bireysel etlik piliçlerin su içme süresini değerlendirmektir (Nasiri ve ark., 2024).

Etlik piliçlerin tartılması; büyümenin izlenmesi, yem yönetimi, sağlık durumunun değerlendirilmesi ve pazar gereksinimlerinin karşılanması açısından kanatlı üretiminde temel bir uygulamadır. Geleneksel tartım yöntemleri, elektronik platform basküller kullanılarak gerçekleştirilmekte; ancak bu yöntemler etlik piliçlerde strese yol açabilmekte ve özellikle ağır hayvanlarda doğru ağırlık verilerinin elde edilmesini zorlaştırabilmektedir. Bu sınırlılıkların aşılması amacıyla, vücut ölçülerine dayalı ölçümler yerine etlik piliçlerin farklı büyüme dönemlerindeki morfolojik değişimlerine dayanan kamera tabanlı bir tartım yaklaşımı önerilmiştir (Shams ve ark., 2025).

Kanatlı üretiminde karşılaşılan hastalık yayılımı, iş gücü yetersizliği, etkin izleme eksikliği ve artan hayvan refahı talebi gibi temel sorunları ele almaktadır. Bu problemlere çözüm olarak, derin

öğrenmeye dayalı gelişmiş bir makine görüşü sistemi önerilmiş ve kanatlıların otomatik izlenmesi ile yönetimi için YOLOv11 algoritması kullanılmıştır (Natho ve ark., 2025).

Küresel etlik piliç eti talebindeki artış, üretkenliğin, hayvan refahının ve sürdürülebilirliğin artırılması amacıyla hassas hayvancılık uygulamalarının önemini daha da belirgin hâle getirmiştir. Çevresel faktörlerin, özellikle sıcaklık ve nemin, etlik piliç performans göstergeleri üzerindeki etkisini modellemek amacıyla Nesnelerin İnterneti sensör ağları ile aşırı gradyan artırma algoritması entegre edilmiştir. İncelenen performans göstergeleri arasında yem tüketimi, canlı ağırlık ve yem dönüşüm oranı yer almaktadır (Adli ve ark., 2025).

Küçük ölçekli kanatlı işletmeleri çoğunlukla gelişmiş izleme araçlarına erişimden yoksundur ve sürü yönetimi için büyük ölçüde manuel gözleme dayanmaktadır. Bu yaklaşım zaman alıcı, tutarsız ve hassas sürü yönetimi için yetersiz kalmaktadır. Yemleme ve su içme davranışları, sağlık ve çevresel sorunların erken göstergeleri olması bakımından kritik öneme sahiptir. Özellikle aynı anda en fazla 10–15 tavuğun barındırıldığı küçük kümes ortamları için tasarlanmış, bilgisayarlı görü tabanlı bir tavuk davranışı izleme sisteminin geliştirilmesini sunmaktadır (İtaliya ve ark., 2025).

Çiftliklerde ve araştırma ortamlarında hayvan refahının izlenmesi, hem etik gerekçeler hem de stres veya hastalıkların erken tespiti yoluyla verimliliğin artırılması açısından giderek daha fazla ilgi görmektedir. İyi aydınlatma koşulları gerektiren ve belirli hayvanların takibinde zorluklar yaşayan video tabanlı izleme yöntemlerinin aksine, giyilebilir cihazların minyatürleştirilmesindeki son gelişmeler ivme, konum ve hareket verilerinin toplanmasına olanak tanıyarak bireysel hayvan davranışının izlenmesini mümkün kılmaktadır (Khan ve ark., 2025).

Horoz davranışı ve aktivitesi, etlik piliç ve yumurtacı damızlık sürülerinde yumurta döllülüğü ve kuluçka randımanı açısından kritik öneme sahiptir. İstenilen özelliklere sahip horozların iyi bacak sağlığına sahip olması, cinsel olgunluğa ulaşması, yüksek üretkenlik göstermesi ve çiftleşme sırasında dişilere karşı daha az agresif davranması beklenmektedir. Bununla birlikte tüm horozlar bu özellikleri taşımamakta; düşük verimli bireylerin sürüden çıkarılarak yerlerinin değiştirilmesi gerekmektedir. Derin öğrenme tabanlı bir nesne tespit modeli kullanarak kafes dışı yetiştirme ortamında tavuk ve horozları ibik büyüklüğü ve vücut ölçüsü gibi fenotipik özelliklere dayalı olarak tanımlamak ve uygulanan modellerin performans metriklerini karşılaştırmaktır (Paneru ve ark., 2025).

Tavuklarda yem arama davranışı, hayvan refahının önemli bir göstergesidir. Bu davranış hem yem arayışını hem de çevrenin keşfini içermekte ve hayvanlar için gerekli çevresel zenginleştirmeyi sağlamaktadır. Ayrıca şiddetli tüy yolma gibi zararlı davranışlarla ters yönlü ilişkili olduğu bilinmektedir. Geleneksel çalışmalar, yem arama davranışının konumu, süresi, zamanı ve sıklığını incelemek için manuel gözleme dayanmaktadır. Ancak bu yaklaşım iş gücü yoğun, zaman alıcı ve insan kaynaklı yanlılıklara açıktır. Kafes dışı bir araştırma ortamında yem arayan tavukları otomatik olarak tespit edebilen bilgisayarlı görü tabanlı yöntemler geliştirilmiş ve performansları karşılaştırılmıştır (Dahal ve ark., 2025).

Tablo 3. Kanatlı Üretiminde Yapay Zekâ Tabanlı İzleme ve Analiz Çalışmalarının Literatüre İlişkin Yapılan Çalışmaların Karşılaştırılması

Amaç	Yapay Zekâ Yöntemi	Başarı Oranı	Araştırma Alanı	Kaynaklar
Otomatik tavuk sayım sistemi geliştirmek ve doğrulamak	YOLOv8	Hassasiyet %93,1 Geri çağırma %93,0	• Sürü yönetimi	(Cruz et al., 2024)
Bireysel piliç izleme ve lokomasyon analizi	YOLOv7-tiny + SORT	Hassasiyet %0,99 Recall %0,99	• Davranış izleme	(Doornweerd et al., 2024)
Karkas kusur ve kalite değerlendirme	CarcassFormer Transformer	AP, AP50, AP75 ↑	Karkas kalite	(Tran et al., 2024)
Piliç vokalizasyon tespiti	CNN (11×2D + 1×1D)	Doğruluk %91,1	Refah izleme	(Soster et al., 2025)
Aktivite periyodu izleme	U-Net İzleme GMM	+ F-score 0,94 + • MOT %74,7	Davranış analizi	(Campbell et al., 2024)
Termal segmentasyon ve sıcaklık analizi	Segment Anything	F1 %92,3	Termal refah izleme	(Saeidifar et al., 2024)

Amaç	Yapay Zekâ Yöntemi	Başarı Oranı	Araştırm a Alanı	Kaynaklar
Stres çağırısı sınıflandırma	Transformer ANN	Ortalama hassasiyet 0,97	Stres izleme	(Lev-ron et al., 2025)
Çok kameralı piliç izleme	BroilerTrack	Sayısal veri belirtilmemiş	İzleme & davranış	(Phan et al., 2025)
Su içme süresi tahmini	U-Net + 3D CNN	%83,21 – %88,32	Davranış izleme	(Nasiri et al., 2024)
Canlı ağırlık tahmini	YOLOv8	mAP 0,829	Ağırlık tahmini	(Shams et al., 2025)
Stres vokalizasyon analizi	CNN MFCC	+ %94 doğruluk	Refah izleme	(Neethirajan, 2025)
Otomatik sürü izleme	YOLOv11	mAP 0,963	Akıllı işletme	(Natho et al., 2025)
Çevresel performans modelleme	IoT XGBoost MLP	+ Sayısal veri + belirtilmemiş	Performans tahmini	(Adli et al., 2025)
Yemleme & su içme davranışı	YOLOv8	mAP %91,5	Davranış izleme	(İtaliya et al., 2025)
Giyilebilir refah izleme	IMU + UWB	<20 cm hata	Refah aktivite	& (Khan et al., 2025)
Horoz/tavuk tanımlama	YOLOv5u YOLOv11	+ Doğruluk %89,0	Seleksiyon	(Paneru et al., 2025)

Amaç	Yapay Zekâ Yöntemi	Başarı Oranı	Araştırm a Alanı	Kaynaklar
Yem arama davranışı	YOLOv9-10-11	mAP %89,5	Davranış analizi	(Dahal et al., 2025)
Akıllı kesim izleme	YOLOv4 + IoT	mAP %94	Kesimhan e refah	(Lin & Suhendra, 2025)
Vokalizasyon AI derlemesi	CNN, LSTM, wav2vec2 vb.	>%95 (derleme)	Refah izleme	(Manikandan & Neethirajan, 2025)

SONUÇ

Küresel kanatlı sektörünün artan hayvansal protein talebine bağlı olarak hızla genişlemesi; üretkenlik, sürdürülebilirlik ve hayvan refahını eş zamanlı sağlayabilecek ileri dijital teknolojilerin entegrasyonunu ortaya çıkarmaktadır. Yapay zekânın; bilgisayarlı görme, Nesnelerin İnterneti, uç bilişim, robotik sistemler ve sensör tabanlı izleme teknolojileriyle birlikte modern kanatlı üretiminde dönüştürücü bir çerçeve sunduğunu ortaya koymaktadır. Yapay zekâ destekli uygulamalar; gerçek zamanlı izleme, erken hastalık tespiti, otomatik sürü sayımı, canlı ağırlık tahmini, davranış analizi, çevresel kontrol ve refah değerlendirmesi gibi kritik yönetim süreçlerini iyileştirmektedir. Bilgisayarlı görme, kızılötesi termografi, radyo Frekans ile Tanımlama ve akustik analiz gibi tespit teknolojilerinin karşılaştırmalı değerlendirilmesi; hassas izleme ve karar destek süreçlerinde tamamlayıcı avantajlar sağladığını göstermektedir. Çok modlu veri entegrasyonu yönetim doğruluğunu artırırken, Dijital İkiz teknolojisi fizyolojik ve davranışsal tepkilerin simülasyonu yoluyla öngörü kapasitesini güçlendirmektedir. Literatür bulguları, kanatlı hayvan sektöründe yapay zekâ entegrasyonunun hayvan refahı, ekonomi ve çevre boyutlarında sürdürülebilirliğe katkı sağladığını; iş gücü masraflarını azalttığını, yem ve enerji kullanım etkinliğini artırdığını ve emisyonların azaltılmasını desteklediğini göstermektedir. Sonuç olarak, kanatlı üretiminde yapay zekâ entegrasyonu; hem emek yoğun gözleme dayalı yaklaşımlardan akıllı, otomatik ve kanıta dayalı yönetim sistemlerine hem de sürdürülebilir kanatlı hayvancılığın sosyal, ekonomik ve çevresel ilkelerine büyük katkı sağlayarak sektörü dönüştürmektedir.

KAYNAKÇA

Abbas, A. O., Nassar, F. S., & Al Ali, A. M. (2025). Challenges of ensuring sustainable poultry meat production and economic resilience under climate change for achieving sustainable food security. *Research in World Agricultural Economics*, 6, 159–171.

Abdelrahman, M., Issa, S., Elsayed Ali, M., Alotaibi, J., & Alshanbari, F. (2026). From machine learning to digital twin integration for livestock production and research. *Frontiers in Veterinary Science*, 13, 1744053. <https://doi.org/10.3389/fvets.2026.1744053>

Adli, D. N., Fatyanosa, T. N., Al Huda, F., Sholikin, M. M., & Sugiharto, S. (2025). Modelling the growth performance and thermal environment of broiler chicken houses via different machine learning algorithms assisted by a customized Internet of Things. *Smart Agricultural Technology*, 12, 101421. <https://doi.org/10.1016/j.atech.2025.101421>

Bist, R.B.; Asnayanti, A.; Do, A.D.T.; Tian, Y.; Pallerla, C.; Wang, D.; Alrubaye, A.A.K. Automated Detection of Kinky Back in Broiler Chickens Using Optimized Deep Learning Techniques. *AgriEngineering* 2025, 7, 415. <https://doi.org/10.3390/agriengineering7120415>.

Brassó, L. D., Komlósi, I., & Várszegi, Z. (2025). Modern technologies for improving broiler production and welfare: A review. *Animals*, 15, 493.

Bretas, I. L., Dubeux, J. C., Jr., Cruz, P. J., Oduor, K. T., Queiroz, L. D., Valente, D. S., & Chizzotti, F. H. (2024). Precision livestock farming applied to grazing land monitoring and management—A review. *Agronomy Journal*, 116, 1164–1186.

Campbell, M., Miller, P., Díaz-Chito, K., Hong, X., McLaughlin, N., Parvinzmir, F., Martínez Del Rincón, J., & O'Connell, N. (2024). A computer vision approach to monitor activity in commercial broiler chickens using trajectory-based clustering analysis. *Computers and Electronics in Agriculture*, 217, 108591. <https://doi.org/10.1016/j.compag.2023.108591>

Cruz, E., Hidalgo-Rodriguez, M., Acosta-Reyes, A. M., Rangel, J. C., & Boniche, K. (2024). AI-based monitoring for enhanced poultry flock management. *Agriculture*, 14(12), 2187. <https://doi.org/10.3390/agriculture14122187>

da Rocha Balthazar, G.; Silveira, R.M.F.; da Silva, I.J.O. Design and Prototyping of a Robotic Structure for Poultry Farming. *AgriEngineering* 2025, 7, 233

Dahal, S., Yang, X., Paneru, B., Dhungana, A., & Chai, L. (2025). Automatic detection of foraging hens in a cage-free environment with computer vision technology. *Poultry*, 4, 34. <https://doi.org/10.3390/poultry4030034>

de Souza, M.A.; de Sousa, F.C.; da Silva, A.L.; Soares, T.C.; Oliveira, C.P.; Vigoderis, R.B.; da Baêta, F.C.; de Tinôco, I.F.F. Effect of Green Roofs on the Thermal Environment of Prototype Broiler Houses. *AgriEngineering* 2025, 7, 16.

Distante, D., Albanello, C., Zaffar, H., Faralli, S., & Amalfitano, D. (2025). Artificial intelligence applied to precision livestock farming: A tertiary study. *Smart Agricultural Technology*, 11, 100889. <https://doi.org/10.1016/j.atech.2025.100889>

Doornweerd, J. E., Veerkamp, R. F., de Klerk, B., van der Sluis, M., Bouwman, A. C., Ellen, E. D., & Kootstra, G. (2024). Tracking individual broilers on video in terms of time and distance. *Poultry Science*, 103(1), 103185. <https://doi.org/10.1016/j.psj.2023.103185>

Engelbrecht, D., Steyn, N., Djouani, K., & Bosman, H. (2026). Precision farming: A review of artificial intelligence applications in broiler poultry farming. *Emirates Journal of Food and Agriculture*, 38, 1–13. <https://doi.org/10.3897/ejfa.2026.172240>

Essien, D., & Neethirajan, S. (2025). Multimodal AI systems for enhanced laying hen welfare assessment and productivity optimization. *Smart Agricultural Technology*, 12, 101564. <https://doi.org/10.1016/j.atech.2025.101564>

Fan, W., Peng, H., & Yang, D. (2025). Review: The application and challenges of advanced detection technologies in poultry farming. *Poultry Science*, 104(11), 105870. <https://doi.org/10.1016/j.psj.2025.105870>

Franzo, G., Legnardi, M., Faustini, G., Tucciarone, C. M., & Cecchinato, M. (2023). When everything becomes bigger: Big data for big poultry production. *Animals*, 13(11), 1804.

Hsieh, C. W., Hsu, S. Y., Chao, C. H., Lee, M. C., Chen, C. Y., & Wu, C. H. (2025). Implementing an intelligent chicken aviary using deep learning techniques. *Multimedia Tools and Applications*, 84, 1–30.

Italiya, J., Ahmed, A. A., Abdel-Wareth, A. A. A., & Lohakare, J. (2025). An AI-based system for monitoring laying hen behavior using computer vision for small-scale poultry farms. *Agriculture*, 15, 1963. <https://doi.org/10.3390/agriculture15181963>

Kaswan, S., Chandratre, G. A., Upadhyay, D., Sharma, A., Sreekala, S. M., Badgujar, P. C., & Ruchay, A. (2024). Applications of sensors in livestock management. In *Engineering applications in livestock production* (pp. 63–92). Academic Press.

Khan, I., Peralta, D., Fontaine, J., Soster de Carvalho, P., Martinez-Caja, A. M., Antonissen, G., Tuytens, F., & De Poorter, E. (2025). Monitoring welfare of individual broiler chickens using

ultra-wideband and inertial measurement unit wearables. *Sensors*, 25, 811. <https://doi.org/10.3390/s25030811>

Lev-ron, T., Yitzhaky, Y., Halachmi, I., & Druyan, S. (2025). Classifying vocal responses of broilers to environmental stressors via artificial neural network. *Animal*, 19(1), 101378. <https://doi.org/10.1016/j.animal.2024.101378>

Lin, H.-T., & Suhendra. (2025). Development and implementation of an IoT-enabled smart poultry slaughtering system using dynamic object tracking and recognition. *Sensors*, 25, 5028. <https://doi.org/10.3390/s25165028>

Losacco, C., Pugliese, G., Forte, L., Tufarelli, V., Maggiolino, A., & De Palo, P. (2025). Digital transition as a driver for sustainable tailor-made farm management: An up-to-date overview on precision livestock farming. *Agriculture*, 15(13), 1383. <https://doi.org/10.3390/agriculture15131383>

Manikandan, V., & Neethirajan, S. (2025). AI-powered vocalization analysis in poultry: Systematic review of health, behavior, and welfare monitoring. *Sensors*, 25, 4058. <https://doi.org/10.3390/s25134058>

Morsi, N., Khedr, M., Yang, E., Masood, T., Maier, A., Campbell, K., & Wallace, A. (2025). Autonomous poultry farming in the UK: A review of technologies and challenges. In *Proceedings of the 30th International Conference on Automation and Computing (ICAC 2025)*. IEEE. <https://doi.org/10.1109/ICAC65379.2025.11196305>

Nasiri, A., Amirivojdan, A., Zhao, Y., & Gan, H. (2024). An automated video action recognition-based system for drinking time estimation of individual broilers. *Smart Agricultural Technology*, 7, 100409. <https://doi.org/10.1016/j.atech.2024.100409>

Natho, P., Boonying, S., Bonguleaum, P., Tantidontanet, N., & Chamuthai, L. (2025). An enhanced machine vision system for smart poultry farms using deep learning. *Smart Agricultural Technology*, 12, 101083. <https://doi.org/10.1016/j.atech.2025.101083>

Natsir, M. H., Mahmudy, W. F., Tono, M., & Nuningtyas, Y. F. (2025). Advancements in artificial intelligence and machine learning for poultry farming: Applications, challenges, and future prospects. *Smart Agricultural Technology*, 12, 101307. <https://doi.org/10.1016/j.atech.2025.101307>

Neethirajan, S. (2025). Decoding vocal indicators of stress in laying hens: A CNN-MFCC deep learning framework. *Smart Agricultural Technology*, 11, 101056. <https://doi.org/10.1016/j.atech.2025.101056>

Odili, P. O., Daudu, C. D., Adefemi, A., Ekemezie, I. O., & Usiagu, G. S. (2024). Integrating advanced technologies in corrosion and inspection management for oil and gas operations. *Engineering Science & Technology Journal*, 5(2), 597–611.

Olanrewaju, O. M., Abdulhafiz, N., & Liman, A. D. (2024). Review of poultry monitoring using computer vision. *Nigerian Journal of Physics*, 33(1), 108–113. <https://doi.org/10.62292/njp.v33i1.2024.216>

Paneru, B., Bist, R. B., Yang, X., Dhungana, A., Dahal, S., & Chai, L. (2025). Deep learning methods for automatic identification of male and female chickens in a cage-free flock. *Animals*, 15, 1862. <https://doi.org/10.3390/ani15131862>

Paneru, B., Dhungana, A., Dahal, S., & Chai, L. (2026). Artificial intelligence in precision poultry farming: Opportunities, challenges, and future features. *Animal Frontiers*. <https://doi.org/10.1093/af/vfag004>

Pasian, I.M.D.L.; Silveira, R.M.F.; Reple, J.N.; Couto, H.T.Z.; da Silva, I.J.O. Efficiency and Reliability of Broiler Weighing Methods in Commercial Environments: A Comparative Evaluation. *AgriEngineering* 2025, 7, 141. <https://doi.org/10.3390/agriengineering7050141>. 6.

Phan, T., Tran, H. K., Lockett, A., Phillips, I., Vo, H., Le, D., Kidd, M. T., Mason, J., Avendano, S., & Le, N. (2025). BroilerTrack: Automatic multi-camera multi-broiler tracking. *Smart Agricultural Technology*, 12, 101312. <https://doi.org/10.1016/j.atech.2025.101312>

Roy, A., & Rana, T. (2025). Precision livestock farming and its advantage to the environment. *Epidemiology, Environment and Hygiene in Veterinary Public Health*, 6, 343–347.

Saeidifar, M., Li, G., Chai, L., Bist, R., Rasheed, K. M., Lu, J., Banakar, A., Liu, T., & Yang, X. (2024). Zero-shot image segmentation for monitoring thermal conditions of individual cage-free laying hens. *Computers and Electronics in Agriculture*, 226, 109436. <https://doi.org/10.1016/j.compag.2024.109436>

Shams, M. Y., Elmessery, W. M., Oraith, A. A. T., Elbeltagi, A., Salem, A., Kumar, P., El-Messery, T. M., Abd El-Hafeez, T., Abdelshafie, M. F., Abd El-Wahhab, G. G., El-Soaly, I. S., & Elwakeel, A. E. (2025). Automated on-site broiler live weight estimation through YOLO-based segmentation. *Smart Agricultural Technology*, 10, 100828. <https://doi.org/10.1016/j.atech.2025.100828>

Soster, P. de C., Grzywalski, T., Hou, Y., Thomas, P., Dedeurwaerder, A., De Gussem, M., Tuytens, F., Devos, P., Botteldooren, D., & Antonissen, G. (2025). Automated detection of broiler vocalizations: A machine learning approach for broiler chicken vocalization monitoring. *Poultry Science*, 104(5), 104962. <https://doi.org/10.1016/j.psj.2025.104962>

Taleb, H. M., Mahrose, K., Abdel-Halim, A. A., Kasem, H., Ramadan, G. S., Fouad, A. M., Khafaga, A. F., Khalifa, N. E., Kamal, M., Salem, H. M., Alqhtani, A. H., Swelum, A. A., Arczewska-Włosek, A., Świątkiewicz, S., & Abd El-Hack, M. E. (2025). Using artificial intelligence to improve poultry productivity – A review. *Annals of Animal Science*, 25(1), 23–33. <https://doi.org/10.2478/aoas-2024-0039>

Tran, M., Truong, S., Fernandes, A. F. A., Kidd, M. T., & Le, N. (2024). CarcassFormer: An end-to-end transformer-based framework for simultaneous localization, segmentation and classification of poultry carcass defect. *Poultry Science*, 103(8), 103765. <https://doi.org/10.1016/j.psj.2024.103765>

Usturoi, M. G., Ratu, R. N., Crivei, I. C., Veles, I. D., Usturoi, A., Stoica, F., & Radu Rusu, R. M. (2025). Unlocking the power of eggs: Nutritional insights, bioactive compounds, and the advantages of omega-3 and omega-6 enriched varieties. *Agriculture*, 15, 242.

Wu, Z., Willems, S., Liu, D., & Norton, T. (2025). How AI improves sustainable chicken farming: A literature review of welfare, economic, and environmental dimensions. *Agriculture*, 15, 2028. <https://doi.org/10.3390/agriculture15192028>

Zhou, S.; Thornton, T.; Gan, H.; Tabler, T.; Jaihuni, M.; Zhu, X.; Zhao, Y. Impact of Stocking Density on Welfare and Performance of Ross 708 and Cobb 700 Broilers. *AgriEngineering* 2024, 6, 4739–4751. <https://doi.org/10.3390/agriengineering6040271>.

BÖLÜM 2

HASSAS HAYVANCILIKTA SIĞIRLARDA YAPAY ZEKÂ UYGULAMALARI

İrfan İNAN¹

Mehmet Salih KAÇMAZ²

Savaş DEMİR³

GİRİŞ

Küresel ölçekte iklim değişikliği, arazi bozunumu, hayvan refahı, ekonomik krizler ve artan gıda talebi, tarımsal üretim sistemlerinin istikrarı açısından önemli zorluklar oluşturmaktadır. Bu durum, hayvansal üretim bilimini ileriye taşımak için daha yenilikçi yaklaşımlara ve sürdürülebilir, modern hayvancılık yönetimi uygulamalarının önemini açıkça ortaya koymaktadır (Abdelrahman ve ark., 2026; Ghavipanje ve ark., 2025).

Mevcut demografik ve ekonomik büyüme bağlamında et ve süt ürünlerine olan talebin önemli ölçüde artması beklenmektedir. Hayvansal ürünlere yönelik artan talep ve buna karşılık çiftçi ve

¹ Yüksek Ziraat Mühendisi, Van Yüzüncü Yıl Üniversitesi, Hayvan Yetiştirme ve Islahı Anabilim Dalı, Van, Türkiye, Orcid: 0009-0007-0084-1394

² Arş. Gör. Dr., Van Yüzüncü Yıl Üniversitesi, Yemler ve Hayvan Besleme Anabilim Dalı, Van, Türkiye, Orcid: 0000-0003-3419-7342

³ Dr., Van Yüzüncü Yıl Üniversitesi, Tıbbi ve Aromatik Bitkiler Anabilim Dalı, Van, Türkiye, Orcid ID: 0000-0002-3795-8883

yetiřtirici sayısındaki azalma, hayvancılık faaliyetlerinin karmařıklıđını önemli ölçüde artırmıřtır. Bu zorluđun üstesinden gelebilmek amacıyla hassas hayvancılık, sığır gibi çiftlik hayvanlarını sürekli izleyerek sorunları daha erken tespit eden ve üretkenliđi artıran tam otomatik araçların geliştirilmesini hedeflemektedir (Besler ve ark., 2024; Michelena ve ark., 2024).

Hayvancılık sektörü, verimliliđi, hayvan refahını ve sürdürülebilirliđi artırmayı amaçlayan akıllı teknolojilerin entegrasyonu ile önemli bir dönüşüm sürecinden geçmektedir. Hassas hayvancılık, hayvancılık sektöründe önemli bir evrimi temsil etmekte; çiftlik yönetimini dönüřtürerek üretim verimliliđini, sürdürülebilirliđi, ürün kalitesini, çalışma kořullarını ve hayvan refahını iyileřtirme vaadi sunmaktadır. Hassas hayvancılık, sürdürülebilir tarımın geleceđine iliřkin güçlü bir vizyon sunmaktadır.

Bu yaklaşım, bilginin toplanması, iřlenmesi, anlařılması ve uygulanması yoluyla yönetim ve karar verme süreçlerine sistematik bir çerçeve kazandıran, veri ve teknoloji temelli bir strateji ortaya koymaktadır (Bernabucci ve ark., 2025; Papakonstantinou ve ark., 2024; Vlaicu ve ark., 2024).

Hayvancılık sektörü, yapay zekâ ve gelişmiř görsel elektronik izleme teknolojilerinin entegrasyonu ile önemli bir dönüşüm sürecinden geçmektedir. Veri odaklı teknolojilerin sayısı ve çeřitliliđindeki sürekli artış ve hızla gelişen AI yöntemleriyle birlikte, sığır reproduksiyonu alanı yapay zekâ tarafından dönüřtürölmeye hazır bir konumdadır. Yapay zekâ alanındaki son gelişmeler, sürekli gerçek zamanlı veri izleme ve otomatik karar destek sistemlerini mümkün kılarak hayvancılık sektörünü dönüřtörmektedir (Distante ve ark., 2025; Giordano & Laplacette, 2026; Moe ve ark., 2025).

Hayvancılık alanında yapay zekâ; sığırlarda duygusal durumların değerlendirilmesi, beslenme alışkanlıklarının izlenmesi, süt üretiminin analizi, hastalık durumlarının belirlenmesi, yüz tanıma, sayım ve sınıflandırma işlemleri ile zoonotik hastalıkların yayılımının takibi gibi birçok uygulamada giderek daha fazla kullanılmaktadır. Yapay zekâ, sığırlarda üretkenlik, hayvan refahı ve ekolojik dayanıklılık arasında denge kurarak farklı üretim sistemlerinde maliyet etkinliği ve erişilebilirliği güvence altına alan sürdürülebilir hayvancılığı yeniden tanımlayacaktır (Mijwil ve ark., 2023; Zhu ve ark., 2025).

Sığırlarda bilgisayarlı görme teknolojileri, hayvan sağlığı, davranışı ve verimliliğinin otomatik ve girişimsel olmayan yöntemlerle izlenmesini mümkün kılarak süt sığircılığı işletme yönetimi alanını hızla dönüştürmektedir. Özellikle makine öğrenmesi ve derin öğrenme ile bütünleştirilen bilgisayarlı görme tabanlı temassız ölçüm teknikleri, çiftlik hayvanlarında vücut ölçüleri ve canlı ağırlık tahmini açısından önemli bir potansiyel ortaya koymaktadır.

Bilgisayarlı görme, üç boyutlu (3B) yeniden yapılandırma ve akustik analizden yararlanan yapay zekâ tabanlı fenotipik ölçüm yaklaşımları; farklı hayvan türlerinde bireysel tanımlama, davranış, canlı ağırlık ve sağlık durumunun invaziv olmayan ve gerçek zamanlı izlenmesine olanak tanımaktadır. Sensör teknolojilerinde ve üretken yapay zekâ alanında kaydedilen son gelişmeler, davranış izleme ve kestirimci analiz yeteneklerini geliştirerek hassas hayvancılık sistemlerini dönüştürmektedir (Antognoli ve ark., 2025; Eckhardt ve ark., 2025; Xu ve ark., 2025; Zhu ve ark., 2025).

Bu derleme çalışmasının amacı, hem sığırlarda yapay zekâ tabanlı uygulamaların hassas hayvancılık sistemlerindeki kullanım alanlarını incelemek hem de güncel literatür bulguları doğrultusunda bu teknolojilerin hayvan sağlığı, davranış izleme, üretim verimliliği ve sürü yönetimine sağladığı katkıları ortaya koymaktır.

2. Hassas Hayvancılığın Geliştirilmesinin Avantajları

Tarım sektörü; verimliliğin artırılması, hayvan refahının güvence altına alınması ve manuel iş gücüne olan bağımlılığın azaltılması yönünde artan bir baskı altındadır. Buna karşın, geleneksel üretim sistemleri Endüstri 4.0 ve Endüstri 5.0 çözümlerinin benimsenmesinde çoğu zaman geride kalmaktadır. Dijital teknolojiler, özellikle dijital ikizler, fiziksel uygulamaya geçilmeden önce sanal temsil, gerçek zamanlı simülasyon, kestirimsel analiz ve performans doğrulama olanağı sunarak dönüşümsel bir yaklaşım sağlamaktadır ve bu yönüyle maliyet etkin bir kavram kanıtı ortaya koymaktadır (Hurtado ve ark., 2026).

Akıllı hayvancılık, gıda güvenliği ve sürdürülebilir kaynak yönetimine yönelik küresel taleplerin artmasına yanıt olarak hızla gelişmektedir. Bulut-uç-cihaz iş birliğine dayalı hesaplama; dağıtık zekâ, gerçek zamanlı işleme ve uyarlanabilir karar verme olanakları sağlayarak geleneksel merkezi mimarilerin sınırlılıklarını aşan dönüştürücü bir paradigma olarak ortaya çıkmıştır. Akıllı tarım teknolojileri, tarımı daha sürdürülebilir ve dayanıklı bir sektöre dönüştürme potansiyeli taşımaktadır. Hassas tarım, Nesnelerin İnterneti sensörleri ve veri analitiği; kaynak kullanım verimliliğini önemli ölçüde artırabilen, çevresel etkileri azaltabilen ve ürün verimliliğini yükseltebilen temel yeniliklerdir (Muthukumar & Karthick, 2025; Yu ve ark., 2025).

Hassas hayvancılığın gelişmesiyle birlikte, çiftlik hayvanlarına ait fenotipik özelliklerin geleneksel manuel ölçüm yöntemleri; doğruluk, verimlilik ve hayvan refahı açısından modern gereksinimleri karşılamada ciddi biçimde yetersiz kalmaktadır. Bu duruma yanıt olarak, özellikle makine öğrenmesi ve derin öğrenme ile bütünleştirilen bilgisayarlı görü tabanlı temassız ölçüm teknikleri, çiftlik hayvanlarında vücut ölçüleri ve canlı ağırlık tahmini alanında önemli bir potansiyel ortaya koymuştur (Xu ve ark., 2025).

Çiftlik düzeyinde hassas ve yaygın hayvancılık uygulamaları kapsamında giyilebilir sensörler, çevresel izleme ekipmanları ve uzaktan algılama teknolojilerinin kullanımı; üretim izleme, yönetim sorunlarının çözümü, lojistik güçlüklerin giderilmesi, kaynak kullanım etkinliğinin artırılması ve karar alma süreçlerinin iyileştirilmesi açısından geniş kullanım alanı bulmaktadır. Nesnelerin İnterneti'nin çok sayıda sensör, denetleyici ve iletişim protokolü ile entegre edilmesi, çiftliklerde insanların ve makinelerin çalışma biçimini köklü biçimde değiştirmiştir (Bernabucci ve ark., 2025; Pathmudi ve ark., 2023).

Girişimsel olmayan teknolojiler kapsamında yer alan kırmızı-yeşil-mavi görüntüleme sistemleri, derinlik kameraları, üç boyutlu görüntüleme sistemleri ve Nesnelerin İnterneti tabanlı platformlar; günümüzde ayrıntılı biyometrik ve davranışsal verileri gerçek zamanlı olarak toplayabilmektedir. Yapay zekâ algoritmaları ise hastalıkların erken teşhisini mümkün kılmakta, yemleme stratejilerinin optimize edilmesini sağlamakta ve üreme yönetimini iyileştirmektedir (Tedeschi ve ark., 2026). Sığır davranışlarının tanınması, hassas hayvancılık uygulamaları açısından hayvan refahının değerlendirilmesi, sağlık izleme ve akıllı yönetim süreçlerinin desteklenmesi bakımından kritik öneme sahiptir. Bilgisayarlı görme ve derin öğrenme alanındaki gelişmelerle birlikte otomatik davranış analizi hızlı bir evrim süreci geçirmiştir (Yuan ve ark., 2025). Yapay zekâ ve sensör teknolojilerinin entegrasyonu, hassas hayvancılıkta büyük veri üretimini artırarak yüksek verimli fenotipik ölçüm ile genomik seleksiyon arasında güçlü bir sinerji oluşturmuştur. Bilgisayarlı görme ve derin öğrenme yöntemleri, hayvanların sağlık, davranış ve verim özelliklerinin gerçek zamanlı ve invaziv olmayan biçimde izlenmesini sağlamaktadır (Zhu ve ark., 2025).

Tablo 1. Geleneksel hayvancılık, hassas hayvancılık ve yapay zekâ tabanlı hassas hayvancılık yaklaşımlarının karşılaştırılması

Tema	Geleneksel Hayvancılık	Hassas Hayvancılık	Yapay Zekâ Tabanlı Hassas Hayvancılık
İzleme Yöntemi	Manuel gözlem ve periyodik kontrol	Sensörler giyilebilir cihazlarla sürekli izleme	ve Bilgisayarlı görme, derin öğrenme ve temassız gerçek zamanlı izleme
Veri Toplama	Sınırlı ve kayıt temelli	Sensör verileri ve otomatik kayıt sistemleri	Büyük veri, görüntü analizi ve çok modlu veri entegrasyonu
Karar Alma	Deneyime ve gözleme dayalı	Veri destekli ancak kısmen manuel analiz	Otomatik karar destek sistemleri ve kestirimci analiz
Sağlık ve Refah İzleme	Hastalık sonrası müdahale	Erken uyarı sistemleri	Fizyolojik ve davranışsal değişimlerin gerçek zamanlı ve hassas tespiti
Maliyet Verimlilik	ve İş gücü yoğun, değişken verimlilik	Daha kontrollü ve optimize edilmiş üretim	Ölçeklenebilir, maliyet etkin ve üretkenliği artıran akıllı sistemler
Uygulama Zorlukları	İnsan hatası ve izleme yetersizliği	Sensör maliyetleri ve teknik altyapı gereksinimi	Algoritma genellenebilirliği, veri kalitesi ve saha doğrulama gereksinimi
Sürdürülebilirlik	Kaynak kullanımı kontrolsüz olabilir	Kaynak kullanımında optimizasyon	Refah, verimlilik ve ekolojik dayanıklılığı entegre eden sürdürülebilir sistem yaklaşımı

Kaynak: Antognoli et al., 2025 uyarlanmıştır

Bulgular, hassas hayvancılıkta özellikle öğrenme ve algılama temelli yapay zekâ alanlarında geniş bir teknik yelpazenin kullanıldığını göstermektedir. Bu tekniklerin; hayvan tanıma,

anormallik tespiti ile sađlık ve refah izleme gibi grevlerde etkili olduđu belirlenmiřtir. Bununla birlikte, evresel izleme ve srdrlebilirlik konularının grece daha sınırlı ele alındıđı grlmř olup, bu durum gelecekte daha fazla arařtırma gerektiren nemli bir bořluđa iřaret etmektedir (Distant ve ark., 2025). Bununla birlikte, teknolojilerin etkin bir řekilde entegre edilebilmesi iin eđitim ve teknik destek sađlanması da en az finansal teřvikler kadar kritik bir rol oynamaktadır. Politika yapıcılar, teknoloji sađlayıcıları ve tarımsal kurumlar arasındaki iř birliđi; iyi uygulamaların oluřturulması ve yeniliklerin tm blgelerde fayda sađlamasının gvence altına alınması aısından hayati neme sahiptir. Bu iř birliđi, daha srdrlebilir ve hayvan refahı odaklı bir hayvancılık sektrne giden yolu aacaktır (Dell’Unto ve ark., 2025).

3. Sıđırlarda Yapay Zeka Tabanlı Uygulamaların nemi

Dijitalleřme, yařamın tm alanlarında yaygın hle gelmiř olup yapay zek, bilgisayarların verileri anlamlandırabilmesini amalarken; makine đrenmesi, aık biimde programlanmadan karar verebilen sistemlerin geliřtirilmesine olanak tanımaktadır. Yapay zek ve makine đrenmesinin birlikte kullanımı, verimliliđi artırmasının yanı sıra srdrlebilir varlık ynetimi yaklařımlarını teřvik etmesi bakımından da gl bir etki ortaya koymaktadır (Dawkins, 2025; Padhiary ve ark., 2024).

Yapay zek, dijital bir bilgisayarın ya da bilgisayar kontroll bir robotun, genellikle zeki varlıklarla iliřkilendirilen akıl yrtme grevlerini yerine getirebilme yeteneđini ifade etmektedir. İnsan–hayvan–bilgisayar etkileřiminin geleceđi umut verici olmakla birlikte, bu teknolojilerin uygulanması; hayvan refahına bađlılık, řeffaflık ve etik standartlara sıkı bir bađlılıkla ynlendirilmelidir. Bu yaklařım, daha insancıl, daha retken ve daha srdrlebilir tarımsal

retim sistemlerinin geliřtirilmesine katkı saęlayacaktır (De Vries ve ark., 2023; Neethirajan ve ark., 2024).

Yapay zekâ; bilgisayarlı grme, makine ęrenmesi, derin ęrenme, Nesnelerin İnterneti, uę biliřim, robotik sistemler ve veri analitięi teknolojilerinden yararlanarak retkenlięi, srdrlebilirlięi ve hayvan refahını artıran geręek zamanlı ve kanıta dayalı karar alma sreęlerini mmkn kılmaktadır. Kenar yapay zekâ zmleri ise gecikmeyi azaltmakta ve bulut biliřime baęımlılıęı dřrerek dřk baęlantı altyapısına sahip iřletmelerde yerinde izleme uygulamalarını mmkn kılmaktadır (Natsir ve ark., 2025; Paneru ve ark., 2026).

iftlik hayvanlarında saęlık ve refahın izlenmesi, geęmiřte insanlar tarafından manuel olarak yrtlen, zahmetli ve yoęun emek gerektiren bir sreętir. Ancak son yıllardaki teknolojik geliřmelerle birlikte hayvancılık sektr, derin ęrenme modelleriyle gçlendirilmiř ve znde karar verme aracı olarak iřlev gren yapay zekâ ve bilgisayarlı gr temelli en gncel teknikleri benimsemiřtir (Rohan ve ark., 2024).

Hayvancılık alanında yapay zekâ; sığırılarda hayvanların duygusal durumlarının deęerlendirilmesi, beslenme alışkanlıklarının izlenmesi, st retiminin analizi, hastalık durumlarının belirlenmesi, yz tanıma, sayım ve sınıflandırma iřlemleri ile zoonotik hastalıkların yayılımının takibi gibi biręok uygulamada giderek daha fazla kullanılmaktadır. Bu teknikler, insan kaynaklı hataların azaltılmasına katkı saęlamakta ve hayvan yetiřtiricileri ile veteriner hekimlerin hayvan saęlığını daha uzun sre koruyabilmesine ve retkenlięin artırılmasına yardımcı olmaktadır (Mijwil ve ark., 2023).

Hayvancılıkta yapay zekânın artan kullanımı, zellikle byk ok kipli modeller gibi retici yapay zekâdaki geliřmelerle birlikte otomatik refah deęerlendirme aralarının geliřtirilmesini

hızlandırmaktadır. Yapay zekâ tabanlı refah değerlendirme araçları, bireyselleştirilmiş refah değerlendirmesine olanak tanıyarak insan bakımındaki çiftlik hayvanları için, özellikle sığırlar açısından, iyi bir yaşamın sağlanmasına katkı sunabilmektedir (Foris ve ark., 2025).

Sığırların tam bir üreme döngüsü; östrus, ovulasyon, gebelik ve doğum gibi bir dizi biyolojik süreç ve olayın tamamlanmasını gerektirmekte olup bu süreçler yapay zekâ araçları tarafından izlenebilmekte ve tahmin edilebilmektedir. Üreme izleme ve yönetim görevleri ile karar alma süreçleri de yapay zekâ araçları tarafından geliştirilebilmekte veya tamamen yürütülebilmektedir. Etkili yapay zekâ tabanlı araçların geliştirilmesi; veri aracılığıyla hayvan biyolojisinin daha iyi anlaşılmasını ve yönetim ile çevresel faktörlerin yapay zekâ modellerinde kullanılan veriler üzerindeki etkilerinin ortaya konmasını gerektirmektedir (Giordano & Laplacette, 2026).

Geleneksel sığır tartım yöntemleri iş gücü yoğun, zaman alıcı ve hayvanlarda strese yol açabilen uygulamalar olup bu durum hayvan sağlığı ve üretim performansı üzerinde olumsuz etkilere neden olabilmektedir. Bu sorunların giderilmesi amacıyla bilgisayarlı görme ve makine öğrenmesi teknolojilerine dayalı otomatik ve temassız yöntemler geliştirilmektedir. Morfometrik ve davranışsal verilerin birlikte kullanıldığı çok boyutlu yaklaşım, besi sığırlarında canlı ağırlık tahminine daha hassas ve ayrıntılı bir yöntem sunmakta; hayvancılık yönetimi uygulamaları ve ıslah programlarının geliştirilmesi açısından önemli bir potansiyel taşımaktadır (Ruchay ve ark., 2026).

Bilgisayarlı görme temelli yaklaşımlar; süt sığırlarının izlenmesinde otomatik, temassız ve ölçeklenebilir araçlar olarak ortaya çıkmış, böylece etkili sürü yönetimi, sağlık değerlendirmesi ve fenotipik veri toplama süreçlerini desteklemiştir (Wang ve ark., 2026).

Büyük ölçekli süt sığırcılığı işletmelerinde bireysel ineklerin hastalık tespiti amacıyla manuel gözlem ve izleme süreçleri önemli zorluklar barındırmaktadır. Bu süreç; yoğun iş gücü gerektirmesi, zaman alıcı olması ve doğruluk düzeyinin düşmesi nedeniyle sınırlı etkinlik göstermektedir. İnsan gözlemine dayalı uygulamalar, hayvan sayısının fazlalığı nedeniyle belirtilerin zamanında fark edilmesini zorlaştırmakta; bu durum hastalık tespitinin doğruluk ve hassasiyetini olumsuz etkilemekte ve dolayısıyla hayvan sağlığı ile işletme verimliliği üzerinde risk oluşturmaktadır. Nesnelerin İnterneti, makine öğrenmesi ve siber-fiziksel sistemlerdeki gelişmeler ise inek sağlığının daha yüksek doğruluk ve daha düşük işletme maliyeti ile otomatik olarak izlenmesine olanak sağlamıştır (Mishra ve ark., 2026).

Sığır davranışlarının doğru biçimde izlenmesi, hassas hayvancılık uygulamalarında sığırlarda sağlık değerlendirmesi, kızgınlık tespiti, doğum izleme ve yem tüketiminin tahmini gibi kritik uygulamaları desteklemektedir. Temaslı ve temassız algılama yöntemleri birlikte kullanılsa da gömülü algılayıcılara (örneğin ivmeölçerler ve basınç algılayıcıları) sahip giyilebilir aygıtlar, davranışların izlenebilirliğini artıran sürekli veri akışları sunmaları nedeniyle önemli avantajlar sağlamaktadır. Küçük makine öğrenmesi yaklaşımları, gelecekte pratik ve ölçeklenebilir davranış izleme çözümlerine yönelik araştırmalara yön verebilecek önemli bir potansiyel sunmaktadır (Ding ve ark., 2025).

Elde edilen bulgular, benzer kapsamlı önceki çalışmalara kıyasla makine öğrenmesi modellerinin performansında iyileşme olduğunu göstermekle kalmamış, aynı zamanda zaman serisi niteliğindeki otomatik sağım sistemi verilerinin gelecekteki olayların öngörülmesinde güçlü ve dayanıklı bir veri kaynağı olduğunu ortaya koymuştur. Gelecekteki çalışmalarda makine öğrenmesi modellerinin performansını daha da artırmak amacıyla otomatik sağım sistemi kayıtlarından ek değişkenlerin dâhil edilmesi

ve diğ er sens r verileri ile entegrasyon saėlanması  nerilmektedir (Dharejo ve ark., 2025). Hayvan bilimciler, m hendisler, bilgisayar bilimciler ve sosyal bilimciler arasındaki disiplinler arası iř birliėinin g  lendirilmesiyle hassas hayvancılık; hayvansal  retimde s rd r lebilir ve verimli uygulamaları geliřtirmeye devam edebilecek, aynı zamanda teknolojilerin geleneksel yetiřtiricilik bilgisinin yerini almak yerine onu tamamlayıcı nitelikte kullanılmasını saėlayacaktır (Tedeschi ve ark., 2026).

4. Sıėırlarda Yapay Zek  Tabanlı Literat re İliřkin Yapılan  alıřmaların Bulguları

S t sıėırlarında topallık, hem hayvan refahını hem de iřletme verimliliėini  nemli  l  de etkileyen yaygın bir sorundur. Geleneksel topallık tespit y ntemleri  oėunlukla hareket bi imi ve sırt eėrililiėindeki deėiřimlere odaklanan  znel g rsel deėerlendirmelere dayanmaktadır. Ancak bu y ntemler,  zellikle erken d nem tespitinde, tutarlılık ve doėruluk a ısından yetersiz kalabilmektedir. Topallık genellikle, hareket ve duruřta g zlemlenen deėiřimlere g re řiddet derecesini sınıflandıran Hareket Skorlama Sistemi kullanılarak deėerlendirilmektedir. Yapay zek  tabanlı bilgisayarlı g rme ile topallık tespiti yapılmaktadır (Narli ve ark., 2025).

Ticari s t sıėırcılığı iřletmeleri,  evresel ısı stresine karřı hayvan refahını ve iřletme s rd r lebilirliėini koruma konusunda  nemli zorluklarla karřı karřıyadır. İkl m deėiřikliėinin bir ok b lgede sıcaklık artıřına yol a ması nedeniyle, ısı stresinin s t sıėırları  zerindeki potansiyel etkilerinin  nceden tahmin edilmesi ve olumsuz etkilerin azaltılması b y k  nem tařımaktadır (Hasan ve ark., 2025).

S t sıėırlarında mastitis, yalnızca hayvan saėlıėı ve refahı a ısından risk oluřturan bir hastalık deėil, aynı zamanda s t sekt r nde doėrudan ve dolaylı b y k ekonomik kayıplara yol a an

en önemli sorunlardan biridir. Son yıllarda otomatik sağım sistemlerinin s t sığırıcılığı işletmelerinde kullanımının ve benimsenmesinin hızla arttığı gör lmektedir. Ancak otomatik sağım sistemleri altında mastitisin tespiti, sağım sırasında s t ve meme dokusunun doğrudan insan gözlemiyle değ rlendirilememesi nedeniyle daha g ç h le gelmektedir (Dharejo ve ark., 2025).

Geleneksel sığır tartım y ntemleri iř g c  yoęun, zaman alıcı ve hayvanlarda strese yol a abilen uygulamalar olup, bu durum hayvan saęlığı ve  retim performansı  zerinde olumsuz etkilere neden olabilmektedir. Bu sorunların giderilmesi amacıyla bilgisayarlı g rme ve makine  ęrenmesi teknolojilerine dayalı otomatik ve temassız y ntemler  nerilmiřtir (Ruchay ve ark., 2026). Modeller farklı sığır ırkları, yař grupları ve barınma kořullarına uyarlanmalıdır.

Sanal  itleme, serbest dolařan  iftlik hayvanlarının y netiminde geleneksel fiziksel bariyerlere alternatif oluřturan, esneklik saęlayan, altyapı maliyetlerini azaltan ve hayvan refahı a ısından olumlu sonu lar sunma potansiyeli tařıyan yenilik i bir yaklařımdır. Bununla birlikte, a ık mera kořullarında sanal  itleme sistemlerinin pratik uygulamalarında  nemli bořluklar bulunmaktadır. Mevcut bilimsel ve ticari sistemlerin tamamı aęırlıklı olarak k resel konumlama sistemi donanımlı tasmalara dayanmaktadır. Ancak bu   z mler; hayvan konumlandırma doęruluęu, davranıř tanıma ve uyarlanabilir sınır uygulama s re leri a ısından  eřitli sınırlılıklar i ermektedir. K resel konumlama sistemi tasmaı kullanılmaksızın sabit kameralar ve insansız hava ara ları potansiyel bilgisayarlı g rme veri kaynakları olarak değ rlendirilmiřtir (Aghazadeh Ardebili ve ark., 2026).

Topallık, s t sığırılarında hayvan refahını ve  retkenliği olumsuz etkileyen yaygın bir saęlık sorunudur. Otomatik topallık tespiti, sınırlı iř g c  ile zamanında teřhis ve tedavi olanaęı saęlayabilir. Duruř tahmini yaklařımı ile  ift y nl  uzun-kısa s reli

bellek temelli sinir ağı mimarisini birleştiren bir topallık tespit yöntemi sunulmuştur (Russello ve ark., 2026).

Bilgisayarlı görme temelli yaklaşımlar; süt sığırlarının izlenmesinde otomatik, temassız ve ölçeklenebilir araçlar olarak ortaya çıkmış, böylece etkili sürü yönetimi, sağlık değerlendirmesi ve fenotipik veri toplama süreçlerini desteklemiştir. Görüntülerden canlı ağırlık tahmini yapılan çalışmalarda aktarım öğrenmesi yaygın olarak kullanılmakla birlikte, bu yaklaşımın etkinliği ve en uygun ince ayar stratejileri hayvancılık uygulamalarında, özellikle de önceden eğitilmiş genel veri seti ağırlıklarının basit kullanımının ötesinde, yeterince anlaşılmamıştır (Wang ve ark., 2026).

Büyük ölçekli süt sığırıcılığı işletmelerinde bireysel ineklerin hastalık tespiti amacıyla manuel gözlem ve izleme süreçleri önemli zorluklar barındırmaktadır. Bu süreç; yoğun iş gücü gerektirmesi, zaman alıcı olması ve doğruluk düzeyinin düşmesi nedeniyle sınırlı etkinlik göstermektedir. İnsan gözlemine dayalı uygulamalar, hayvan sayısının fazlalığı nedeniyle belirtilerin zamanında fark edilmesini zorlaştırmakta; bu durum hastalık tespitinin doğruluk ve hassasiyetini olumsuz etkilemekte ve dolayısıyla hayvan sağlığı ile işletme verimliliği üzerinde risk oluşturmaktadır. Ayrıca inek sağlığının manuel olarak gözlemlenmesi ve izlenmesi için insan kaynağının organize edilmesi ve yönetilmesi karmaşık ve ekonomik açıdan maliyetli bir süreçtir. Bu durum, nitelikli personel gereksinimini artırmakta ve işletme bakım maliyetleri ile operasyonel verimsizliklere yol açmaktadır (Mishra ve ark., 2026).

Rumen asidozu, süt sığırlarında önemli ekonomik kayıplara ve hayvan refahı sorunlarına yol açan yaygın bir metabolik hastalıktır. Mevcut tanı yöntemleri invaziv pH ölçümlerine dayanmakta olup sürekli izleme açısından ölçeklenebilirliği sınırlamaktadır (Islam ve ark., 2026).

Nodüler deri hastalığı ve şap hastalığı, sığırlarda görülen yüksek derecede bulaşıcı viral hastalıklar olup önemli ekonomik kayıplara ve hayvan refahı sorunlarına yol açmaktadır. Bu hastalıkların görsel tanısı; hem birbirleriyle hem de böcek ısırıkları veya kimyasal yanıklar gibi zararsız durumlarla belirti benzerliği göstermeleri nedeniyle güçleşmekte ve zamanında kontrol önlemlerinin alınmasını zorlaştırmaktadır (Ayon ve ark., 2026).

Bireysel ineklerin hassas biçimde tanımlanması, akıllı hayvancılıkta kapsamlı dijital yönetimin temel ön koşullarından biridir. Mevcut hayvan kimliklendirme yöntemleri kontrollü ve tek kamera ortamlarında yüksek performans gösterse de çoklu kamera senaryolarında ciddi genelleme sorunlarıyla karşılaşmaktadır (Wang ve ark., 2026).

Sığırlarda vücut kütlesinin doğru biçimde tahmin edilmesi; sürü izleme, biyolojik verimliliğin değerlendirilmesi ve besleme yönetiminin optimize edilmesi açısından kritik öneme sahiptir. Yapay zekâ destekli yapay sinir ağı çalışmaları yapılmaktadır (de Oliveira ve ark., 2025).

Temassız ve akıllı teknolojiler, tarımsal sistemlerin gerçek zamanlı izlenmesinde kullanılarak hızlı karar alma süreçlerini kolaylaştırmakta ve farklı iklim koşullarında hayvan stresinin azaltılmasına katkı sağlamaktadır. Sığırlarda termal stres durumlarının belirlenmesinde derin öğrenmenin etkili bir teknoloji olduğu gösterilmiştir (da Silva ve ark., 2026).

Hayvan davranışı, fizyolojisi ve üretim verilerini sürekli olarak nicelleştiren dijital teknolojiler; süt sığırlarında sağlık ve refah bozukluklarının erken tanımlanması açısından önemli bir potansiyel sunmaktadır. Meme, bacak ve tırnak enfeksiyonları veteriner hekim tarafından doğrulanmış süt sığırlarında gerçek zamanlı sağlık izleme amacıyla; fizyolojik, davranışsal, üretim ve termal görüntüleme verilerinin entegrasyonuna dayalı çok modlu bir

yapay zekâ çerçevesi önerilmiştir (Paulauskaite-Taraseviciene ve ark., 2026).

Sığır davranışı, hayvanların sağlık durumu ile yakından ilişkilidir ve davranışın akıllı cihazlar aracılığıyla izlenmesi, yetiştiricilerin hassas ve bilimsel hayvancılık yönetimi gerçekleştirmesine yardımcı olabilmektedir. Mevcut davranış tanıma algoritmaları genellikle sunucu tabanlı platformlarda çalıştırılmakta; bu durum uç cihazlardan veri iletimi nedeniyle enerji tüketimini artırmakta ve gerçek zamanlı hesaplamayı zorlaştırmaktadır. Grafik sinir ağları sıkıştırmasına dayalı uç bilişim temelli bir sığır davranış tanıma yöntemi önerilmiştir (Liu ve ark., 2026).

Sığır davranışlarının izlenmesi; çiftlik verimliliğinin artırılması, hayvan refahının korunması ve etkin yönetim uygulamalarının desteklenmesi açısından önemli bir rol oynamaktadır. Bu çalışma, senkronize edilmiş üstten görünüm (top-view) ve önden görünüm (front-view) CCTV görüntülerini derin öğrenme teknikleri ile birleştiren çoklu görüşlü bir davranış tanıma sistemi sunmaktadır (Hanpinitsak ve ark., 2026).

Sığır davranışlarının izlenmesi ve sınıflandırılmasına yönelik hassas ve otonom araçların yetersizliği, çiftçilerin otlatma ve sürü yönetimine ilişkin proaktif ve bilinçli kararlar alma kapasitesini sınırlamaktadır. Günümüzde sığır davranış sınıflandırmasına yönelik standartlaştırılmış bir model bulunmamaktadır. Bu boşluğu gidermek amacıyla ineğin vücudunun farklı bölgelerine (burun, kulak, boyun) yerleştirilen sensörlerden elde edilen ivmeölçer verilerini kullanarak bir Random Forest makine öğrenmesi modeli geliştirilmiştir (James ve ark., 2026).

Süt sığırlarında topallığın üstten görünüm perspektifinden tespit edilmesi, çiftlik ekipmanları veya diğer hayvanlardan kaynaklanan örtülme sorunlarını etkili biçimde azaltabilmektedir.

Ayrıca askıya alınmış tespit cihazları doğal davranışları bozmadan paralel izleme imkânı sunmaktadır. Bununla birlikte bu perspektiften geliştirilen mevcut yöntemler; sırt hareket özelliklerinin inceliği ve bireysel varyasyonlar nedeniyle doğruluk ve genellenebilirlik açısından hâlen çeşitli zorluklarla karşılaşmaktadır. Bu sınırlılıkları gidermek amacıyla RGB-D verilerine dayalı üstten görünüm topallık tespit yaklaşımı incelenmiştir (Duan ve ark., 2025).

Bilgisayarlı görme tabanlı bir anahtar nokta tespit tekniğinin süt sığırlarında üstten görünüm iki boyutlu videolardan hareketlilik skorları ile ilişkili hareket değişkenlerini çıkarmadaki uygulanabilirliği değerlendirilmiştir. Ayrıca çalışma, yeni elde edilen hareketlilik değişkenlerine dayalı olarak hareketlilik skorlarını tahmin edebilen bir makine öğrenmesi sınıflandırma modelinin potansiyelini belirlemeyi hedeflemiştir (Higaki ve ark., 2025).

Bilimsel literatürden davranış verilerinin çıkarılması ve sınıflandırılmasında ChatGPT-4'ün uygulanabilirliğini inceleyen çalışmalar, süt sığırlarının günlük zaman-aktivite bütçesinin analizine odaklanmaktadır. Zaman-aktivite bütçelerinin doğru analizi, süt sığırı refahı ve verimliliğinin anlaşılması açısından kritik öneme sahiptir. Geleneksel yöntemler zaman alıcıdır ve yanlışlık riski taşımaktadır. Bu nedenle çalışmalar, süt sığırı davranış araştırmalarında güvenilirlik ve doğruluğu artırmak amacıyla yapay zekâ yetenekleri ile insan denetimini birleştiren hibrit yaklaşımların benimsenmesini önermektedir (Lamanna ve ark., 2025).

Tablo 2. Sığırlarda Yapay Zekâ Uygulamalarına İlişkin Çalışmaların Özeti

Sığır	Amaç	Yapay Zekâ Yöntemi	Başarı Oranı	Araştırma Alanı	Kaynaklar
Süt sığırları (Holştayn -	Topallığın tespiti ve hareket skorunun sınıflandırılması	Bilgisayarlı görme ve derin öğrenme	%97	Topallık tespiti	(Narli et al., 2025)
Süt sığırları	Isı stresi koşullarında günlük süt verimi tahmini	XGBoost makine öğrenmesi modeli	$R^2 = 0.73$, CCC = 0.84	Isı stresi ve süt verimi	(Hasan et al., 2025)
Süt sığırları	Mastitis durumunun tahmini	Lojistik regresyon, SVM, Karar ağacı, Rastgele orman, Gradyan artırma, MLP	Doğruluk : 0.84–0.93	Mastitis tespiti	(Dharejo et al., 2025)
Besi sığırları	Canlı tahmini	Canlı ağırlık Ekstra ve Ortalama Ağaçlar modeli	Ortalama mutlak hata: –1.9 kg	Canlı ağırlık tahmini	(Ruchay et al., 2026)
Süt sığırları	Video tabanlı topallık tespiti	Pose estimation + Bi-LSTM	%84.5	Topallık tespiti	(Russello et al., 2026)
Süt sığırları	Rumen asidozu tespiti	Çift akışlı derin öğrenme mimarisi	%98.82	Rumen asidozu	(Islam et al., 2026)

Sığır	Amaç	Yapay Zekâ Yöntemi	Başarı Oranı	Araştırma Alanı	Kaynaklar
Sığır	Nodüler deri hastalığı ve şap hastalığının tespiti	Ensemble derin öğrenme	%98.2	Hastalık tespiti	(Ayon et al., 2026)
Süt sığırı	Bireysel inek kimliklendirme	Ayrıştırılmış temsil öğrenmesi tabanlı derin öğrenme	%86.0	Hayvan kimliklendirme	(Wang et al., 2026)
Süt sığırı	Vücut kütlesi tahmini	Yapay sinir ağları	$R^2 = 0.9125$	Canlı ağırlık tahmini	(de Oliveira et al., 2025)
Nelore sığırı	Isı stresi sınıflandırması	Denetimli derin öğrenme modeli	%72	Isı tespiti	stresi (da Silva et al., 2026)
Süt sığırı	Sağlık bozukluklarının erken tespiti	U-Net, O-Net ve ResNet tabanlı hibrit derin öğrenme	%91.62	Hastalık tespiti	(Paulauskaite - Taraseviciene et al., 2026)
Sığır	Davranış sınıflandırması	Grafik sinir ağı sıkıştırması ve S-ResNet	%94.50	Davranış tanıma	(Liu et al., 2026)
Süt sığırı	Davranış tanıma ve östrus tespiti	YOLOv8 tabanlı çoklu kamera derin öğrenme	$F1 = 0.481$	Davranış analizi	(Hanpinitzak et al., 2026)

Sığır	Amaç	Yapay Zekâ Yöntemi	Başarı Oranı	Araştırma Alanı	Kaynaklar
Süt sığırı	Üstten görüntü ile topallık tespiti	Anahtar nokta tespiti Random Forest	+ %91	Topallık tespiti	(Duan et al., 2025)
Süt sığırı	Hareketlilik skoru tahmini	Anahtar nokta tespiti Random Forest	+ AUC = 0.89	Hareketlilik analizi	(Higaki et al., 2025)
Süt sığırı	Literatürden davranış verisi çıkarımı	Büyük Dil Modeli (ChatGPT-4)	%75.4 doğruluk	Davranış araştırmaları	(Lamanna et al., 2025)

Tablo 2 bulgularına göre, sığırlarda yapay zekâ uygulamalarının başlıca kullanım alanları; topallık tespiti, hastalık tanısı, canlı ağırlık tahmini, davranış analizi, ısı stresi belirleme, bireysel hayvan kimliklendirme ve sağlık bozukluklarının erken tespiti olarak öne çıkmaktadır. Çalışmalarda yaygın olarak derin öğrenme, yapay sinir ağları, Random Forest, XGBoost, grafik sinir ağları, LSTM ve ensemble modelleri kullanılmıştır. Elde edilen performans sonuçları incelendiğinde, modellerin başarı oranlarının %72 ile %98,82 arasında değiştiği görülmektedir. Özellikle rumen asidozu tespiti (%98,82) ve bulaşıcı hastalıkların görüntü tabanlı tanısı (%98,2) en yüksek doğruluk değerlerine ulaşan uygulamalar arasında yer almaktadır. Buna karşılık ısı stresi sınıflandırması (%72) daha düşük doğruluk değerine sahip uygulamalardan biri olarak dikkat çekmektedir. Genel olarak değerlendirildiğinde, yapay zekâ tabanlı yöntemlerin sığırlarda sağlık izleme, üretim yönetimi ve davranış analizi gibi alanlarda yüksek doğrulukla uygulanabildiği görülmektedir.

SONUÇ

Bu derleme çalışması, sığırlarda yapay zekâ tabanlı uygulamaların hayvansal üretim sistemlerinde kullanım alanlarını ve literatürde elde edilen bulguları ortaya koymuştur. Çalışma bulgularına göre, yapay zekâ tabanlı entegrasyon özellikle hayvan sağlığı, davranış analizi, üretim verimliliği ve sürü yönetimi gibi alanlarda önemli bir kullanım potansiyeline sahip olduğunu göstermektedir. Bilgisayarlı görme, makine öğrenmesi, derin öğrenme, nesnelerin interneti tabanlı sensör sistemleri ve veri analitiği gibi teknolojiler sayesinde sığırlarda sağlık durumunun izlenmesi, davranışların analiz edilmesi, canlı ağırlık tahmini, hastalıkların erken teşhisi ve üretim süreçlerinin yönetimi daha hızlı ve objektif bir biçimde gerçekleştirilebilmektedir. Literatürde yer alan çalışmalar, yapay zekâ tabanlı sistemlerin topallık tespiti, mastitis ve rumen asidozu gibi hastalıkların belirlenmesi, ısı stresi analizleri, davranış sınıflandırması, bireysel hayvan kimliklendirme ve canlı ağırlık tahmini gibi farklı uygulama alanlarında başarıyla kullanılabildiğini göstermektedir. Bu teknolojiler, özellikle bilgisayarlı görme ve sensör tabanlı veri toplama sistemleri ile birlikte kullanıldığında hayvanların sağlık ve davranış durumlarının insan müdahalesi olmadan izlenmesine olanak sağlamaktadır. Ayrıca yapay zekâ destekli analiz yöntemleri, otomatik karar destek sistemlerinin geliştirilmesine katkı sağlayarak üretim yönetiminde daha etkin ve veri temelli yaklaşımların uygulanmasını mümkün kılmaktadır. Genel olarak değerlendirildiğinde, yapay zekâ tabanlı teknolojilerin sığır yetiştiriciliğinde hem hayvan sağlık izleme, davranış, üretim yönetimi ve hayvan refahının değerlendirilmesi gibi alanlarda önemli katkılar sağladığı hem de hassas hayvancılık uygulamalarının geliştirilmesinde önemli katkılar sağladığı görülmektedir.

KAYNAKÇA

Abdelrahman, M., Issa, S., Elsayed Ali, M., Alotaibi, J., & Alshanbari, F. (2026). From machine learning to digital twin integration for livestock production and research. *Frontiers in Veterinary Science*, 13, 1744053. <https://doi.org/10.3389/fvets.2026.1744053>

Aghazadeh Ardebili, A., Boscolo, M., & Padoano, E. (2026). Computer vision-enabled smart farms for cattle herd management in open-pasture. *Smart Agricultural Technology*, 13, 101809. <https://doi.org/10.1016/j.atech.2026.101809>

Antognoli, V., Presutti, L., Bovo, M., Torreggiani, D., & Tassinari, P. (2025). Computer vision in dairy farm management: A literature review of current applications and future perspectives. *Animals*, 15, 2508. <https://doi.org/10.3390/ani15172508>

Ayon, N. B., Hasib, A., Ahmed, M. F., Rahman, M. S., Islam, K., Hasan, T. M. M., & Sarkar Akib, A. S. M. A. (2026). Simultaneous detection of LSD and FMD in cattle using ensemble deep learning. *arXiv*. <https://doi.org/10.48550/arXiv.2601.12889>

Bernabucci, G., Evangelista, C., Girotti, P., Viola, P., Spina, R., Ronchi, B., Bernabucci, U., Basiricò, L., Turini, L., Mantino, A., Mele, M., & Primi, R. (2025). Yaygın hayvancılık sistemlerinde hassas hayvancılık uygulamalarına genel bir bakış. *Italian Journal of Animal Science*, 24(1), 859–884. <https://doi.org/10.1080/1828051X.2025.2480821>

Besler, B. C., Mojabi, P., Lasemiimani, Z., Murphy, J. E., Wang, Z., Baker, R., Pearson, J. M., & Fear, E. C. (2024). Scoping review of precision technologies for cattle monitoring. *Smart Agricultural Technology*, 9, 100596. <https://doi.org/10.1016/j.atech.2024.100596>

da Silva, W. C., da Silva, J. A. R., Martorano, L. G., da Silva, É. B. R., de Araújo, C. V., Camargo-Júnior, R. N. C., Neves, K. A. L., Belo, T. S., Joaquim, L. A., Rodrigues, T. C. G. C., e Silva, A. G. M., & Lourenço-Júnior, J. B. (2026). A supervised deep learning model was developed to classify Nelore cattle (*Bos indicus*) with heat stress in the Brazilian Amazon. *Animals*, 16, 161. <https://doi.org/10.3390/ani16020161>

Dawkins, M. S. (2025). Smart farming and artificial intelligence: How can we ensure that animal welfare is a priority? *Applied Animal Behaviour Science*, 283, 106519. <https://doi.org/10.1016/j.applanim.2025.106519>

de Oliveira, F. M., Ferraz, P. F. P., Ferraz, G. A. e S., Pereira, M. N., Barbari, M., & Rossi, G. (2025). Prediction of body mass of dairy cattle using machine learning algorithms applied to morphological characteristics. *Animals*, 15(7), 1054. <https://doi.org/10.3390/ani15071054>

De Vries, A., Bliznyuk, N., & Pinedo, P. (2023). Invited review: Examples and opportunities for artificial intelligence in dairy farms. *Applied Animal Science*, 39, 14–22. <https://doi.org/10.15232/aas.2022-02345>

Dell’Unto, D., Selvaggi, R., Pappalardo, G., & Cortignani, R. (2025). Adoption of precision livestock farming devices in the dairy cattle sector: An assessment based on agroeconomic modelling. *Science of the Total Environment*, 1002, 180555. <https://doi.org/10.1016/j.scitotenv.2025.180555>

Dharejo, M. N., Minogue, L., Kabelitz, T., Amon, T., Kashongwe, O., & Doherr, M. G. (2025). Time series data analysis to predict the status of mastitis in dairy cows by applying machine learning models to automated milking systems data. *Preventive Veterinary Medicine*, 242, 106575. <https://doi.org/10.1016/j.prevetmed.2025.106575>

Dharejo, M. N., Minogue, L., Kabelitz, T., Amon, T., Kashongwe, O., & Doherr, M. G. (2025). Time series data analysis to predict the status of mastitis in dairy cows by applying machine learning models to automated milking systems data. *Preventive Veterinary Medicine*, 242, 106575. <https://doi.org/10.1016/j.prevetmed.2025.106575>

Ding, L., Zhang, C., Yue, Y., Yao, C., Li, Z., Hu, Y., Yang, B., Ma, W., Yu, L., Gao, R., et al. (2025). Wearable sensors-based intelligent sensing and application of animal behaviors: A comprehensive review. *Sensors*, 25, 4515. <https://doi.org/10.3390/s25144515>

Distante, D., Albanello, C., Zaffar, H., Faralli, S., & Amalfitano, D. (2025). Artificial intelligence applied to precision livestock farming: A tertiary study. *Smart Agricultural Technology*, 11, 100889. <https://doi.org/10.1016/j.atech.2025.100889>

Duan, W., Wang, F., Li, H., Liu, N., & Fu, X. (2025). Lameness detection in dairy cows from overhead view: High-precision keypoint localization and multi-feature fusion classification. *Frontiers in Veterinary Science*, 12, 1675181. <https://doi.org/10.3389/fvets.2025.1675181>

Eckhardt, R., Arablouei, R., Ingham, A., McCosker, K., & Bernhardt, H. (2025). Üretken yapay zekâ yoluyla hayvan davranışlarının öngörülmesi. *Smart Agricultural Technology*, 11, 100987. <https://doi.org/10.1016/j.atech.2025.100987>

Foris, B., Sheng, K., Dürnberger, C., Oczak, M., & Rault, J.-L. (2025). Artificial intelligence for One Welfare: The role of animal welfare scientists in developing valid and ethical AI-based welfare assessment tools. *Frontiers in Veterinary Science*, 12, 1645901. <https://doi.org/10.3389/fvets.2025.1645901>

Ghavipanje, N., Fathi Nasri, M. H., & Vargas-Bello-Pérez, E. (2025). Trends and future directions of artificial intelligence applications in Iranian livestock production systems: A review. *Annals of Animal Science*, 25(3), 865–874. <https://doi.org/10.2478/aoas-2024-0098>

Giordano, J. O., & Laplacette, A. L. (2026). Present and future opportunities for artificial intelligence applications in dairy cattle reproduction. *Animal Frontiers*. Advance online publication. <https://doi.org/vfag007>

Hanpinitsak, P., Katanyukul, T., Tonmitr, N., Suntra, C., Tanusilp, S., & Phuphaphud, A. (2026). Artificial intelligence-based dairy cattle behavior recognition for estrus detection via ensemble fusion of two camera views. *PLOS ONE*, 21(1), e0340999. <https://doi.org/10.1371/journal.pone.0340999>

Hasan, M. F., Celik, N., Williams, Y., Williams, S. R. O., & Marett, L. C. (2025). An effective way to incorporate temperature–humidity index to study effect of heat stress on milk yield by an XGBoost machine learning model. *Journal of Dairy Science*, 108, 13995–14017. <https://doi.org/10.3168/jds.2025-27193>

Higaki, S., Menezes, G. L., Ferreira, R. E. P., Negreiro, A., Cabrera, V. E., & Dórea, J. R. R. (2025). Objective dairy cow mobility analysis and scoring system using computer vision–based keypoint detection technique from top-view two-dimensional videos. *Journal of Dairy Science*, 108(5), 3942–3955. <https://doi.org/10.3168/jds.2024-25545>

Hurtado, E., Suryadevara, C., Walker, J., Tayag, G., & Ryait, H. (2026). Digital twins as decision-support tools for automation in agriculture: A case study on robotic vaccination. *Smart Agricultural Technology*, 13, 101675. <https://doi.org/10.1016/j.atech.2025.101675>

James, H., Rial, C., Giordano, J., & Erickson, D. (2026). Advancing standardized cattle behavior classification with a random forest model evaluated across diverse datasets. *Frontiers in Animal Science*, 7, 1676504. <https://doi.org/10.3389/fanim.2026.1676504>

Lamanna, M., Muca, E., Giannone, C., Bovo, M., Boffo, F., Romanzin, A., & Cavallini, D. (2025). Artificial intelligence meets dairy cow research: Large language model's application in extracting daily time-activity budget data for a meta-analytical study. *Journal of Dairy Science*, 108(9), 10203–10219. <https://doi.org/10.3168/jds.2025-26385>

Liu, H., Song, P., Xin, X., Rong, Y., Gao, J., Wang, Z., & Zhang, Y. (2026). A cattle behavior recognition method based on graph neural network compression on the edge. *Animals*, 16(3), 430. <https://doi.org/10.3390/ani16030430>

Michelena, Á., Fontenla-Romero, O., & Calvo-Rolle, J. L. (2024). A review and future trends of precision livestock over dairy and beef cow cattle with artificial intelligence. *Logic Journal of the IGPL*, 33(4). <https://doi.org/10.1093/jigpal/jzae111>

Mijwil, M. M., Adelaja, O., Badr, A., Ali, G., Buruga, B. A., & Pudasaini, P. (2023). Innovative livestock: A survey of artificial intelligence techniques in livestock farming management. *Wasit Journal of Computer and Mathematics Science*, 5(2), xx–xx. <https://doi.org/10.52866/ijcsm.0000.00.00.000>

Mijwil, M. M., Adelaja, O., Badr, A., Ali, G., Buruga, B. A., & Pudasaini, P. (2023). Innovative livestock: A survey of artificial intelligence techniques in livestock farming management. *Wasit Journal of Computer and Mathematics Science*, 5(2), xx–xx. <https://doi.org/10.52866/ijcsm.0000.00.00.000>

Mishra, R. R., Chandrasekhar Rao, D., & Tripathy, A. K. (2026). Smart IoT-based wearable device for detection and

monitoring of common cow diseases using a novel machine learning technique. *arXiv*. <https://doi.org/10.48550/arXiv.2601.04761>

Moe, A. S. T., Tin, P., Aikawa, M., Kobayashi, I., & Zin, T. T. (2025). AI-powered visual E-monitoring system for cattle health and wealth. *Smart Agricultural Technology*, 12, 101300. <https://doi.org/10.1016/j.atech.2025.101300>

Muthukumar, M., & Karthick, A. (2025). Recent progress in the implementation of sustainable farming. *Measurement: Sensors*, 39, 101877. <https://doi.org/10.1016/j.measen.2025.101877>

Narli, S. S., Schmidt, H., Firouzabadi, A., Schönnagel, L., Reich, M. S., & Reitmaier, S. (2025). Automated detection of lameness in dairy cattle through computer vision analysis of back shape characteristics. *Computers in Biology and Medicine*, 197, 111038. <https://doi.org/10.1016/j.compbiomed.2025.111038>

Natsir, M. H., Mahmudy, W. F., Tono, M., & Nuningtyas, Y. F. (2025). Advancements in artificial intelligence and machine learning for poultry farming: Applications, challenges, and future prospects. *Smart Agricultural Technology*, 12, 101307. <https://doi.org/10.1016/j.atech.2025.101307>

Padhiary, M., Saha, D., Kumar, R., Sethi, L. N., & Kumar, A. (2024). Enhancing precision agriculture: A comprehensive review of machine learning and AI vision applications in all-terrain vehicle for farm automation. *Smart Agricultural Technology*, 8, 100483. <https://doi.org/10.1016/j.atech.2024.100483>

Paneru, B., Dhungana, A., Dahal, S., & Chai, L. (2026). Artificial intelligence in precision poultry farming: Opportunities, challenges, and future features. *Animal Frontiers*. <https://doi.org/10.1093/af/vfag004>

Papakonstantinou, G. I., Voulgarakis, N., Terzidou, G., Fotos, L., Giamouri, E., & Papatsiros, V. G. (2024). Precision livestock

farming technology: Applications and challenges of animal welfare and climate change. *Agriculture*, 14, 620. <https://doi.org/10.3390/agriculture14040620>

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>

Paulauskaite-Taraseviciene, A., Nakrosis, A., Zymantiene, J., Jurenas, V., Vezys, J., Sederevicius, A., Gruzauskas, R., Oberauskas, V., Japertiene, R., & Ostasevicius, V. (2026). AI-driven multimodal sensing for early detection of health disorders in dairy cows. *Animals*, 16(3), 411. <https://doi.org/10.3390/ani16030411>

Rohan, A., Rafaq, M. S., Hasan, M. J., Asghar, F., Bashir, A. K., & Dottorini, T. (2024). Application of deep learning for livestock behaviour recognition: A systematic literature review. *Computers and Electronics in Agriculture*, 224, 109115. <https://doi.org/10.1016/j.compag.2024.109115>

Ruchay, A., Kolpakov, V., Guo, H., & Pezzuolo, A. (2026). Optimising automatic cattle weight estimation based on computer vision through animal temperament assessment. *Computers and Electronics in Agriculture*, 243, 111395. <https://doi.org/10.1016/j.compag.2025.111395>

Russello, H., van der Tol, R., van Henten, E. J., & Kootstra, G. (2026). Lameness detection in dairy cows using pose estimation and bidirectional LSTMs. *Smart Agricultural Technology*, 13, 101831. <https://doi.org/10.1016/j.atech.2026.101831>

Tedeschi, L. O., Guarnido-Lopez, P., Menendez, H. M., III, & Seo, S. (2026). Advancing precision livestock farming: Integrating artificial intelligence and emerging technologies for

sustainable livestock management: Review. *Animal Bioscience*. Advance online publication. <https://doi.org/10.5713/ab.25.0289>

Vlaicu, P. A., Gras, M. A., Untea, A. E., Lefter, N. A., & Rotar, M. C. (2024). Advancing livestock technology: Intelligent systemization for enhanced productivity, welfare, and sustainability. *AgriEngineering*, 6, 1479–1496. <https://doi.org/10.3390/agriengineering6020084>

Wang, J., De Castro, A., Zhang, Y., Borsatto, L. B., Guo, Y., Primo, V. B., Monteverchio Bernardino, A. B., Morota, G., Chebel, R. C., & Yu, H. (2026). Evaluating transfer learning strategies for improving dairy cattle body weight prediction in small farms using depth-image and point-cloud data. *arXiv*. <https://doi.org/10.48550/arXiv.2601.01044>

Wang, R., Yaru, C., Zhang, G., & Jiang, H. (2026). Cross-camera cow identification via disentangled representation learning. *arXiv*. <https://doi.org/10.48550/arXiv.2602.07566>

Wang, Y., Mücher, S., Wang, W., Guo, L., & Kooistra, L. (2023). A review of three-dimensional computer vision used in precision livestock farming for cattle growth management. *Computers and Electronics in Agriculture*, 206, 107687. <https://doi.org/10.1016/j.compag.2023.107687>

Xu, J., Jiang, W., Wang, L., Wang, H., Wu, J., Shen, Y., Zhu, C., Hao, S., & Liu, C. (2025). Recent advances in computer vision for non-contact phenotyping and weight estimation in livestock: A systematic review. *Information Processing in Agriculture*. Advance online publication. <https://doi.org/10.1016/j.inpa.2025.10.003>

Yu, P., Teng, F., Zhu, W., Shen, C., Chen, Z., & Song, J. (2025). Cloud–edge–device collaborative computing in smart agriculture: Architectures, applications, and future perspectives.

Frontiers in Plant Science, 16, 1668545.
<https://doi.org/10.3389/fpls.2025.1668545>

Yuan, L., Li, W., Yue, J., Li, Z., Zhao, Y., Li, Q., Feng, W., & Kou, G. (2025). A review of cattle behavior recognition methods based on computer vision and deep learning. *Smart Agricultural Technology*. Advance online publication.
<https://doi.org/10.1016/j.atech.2026.101867>

Zhu, L., Yang, X., Xian, Y., Jiang, W., Pu, X., Wang, S., Cheng, J., Niu, L., Zhao, Y., Chen, L., Zhou, X., Wang, Y., Gan, M., Zhu, L., & Shen, L. (2025). Empowering precision livestock farming: Artificial intelligence applications in animal genomic breeding and multi-dimensional phenotypic measurement. *Smart Agricultural Technology*, 12, 101655.
<https://doi.org/10.1016/j.atech.2025.101655>

BÖLÜM 3

SÜRDÜRÜLEBİLİR TARIM SİSTEMLERİ: İLKELER ETKİLER ZORLUKLAR FIRSATLAR VE GELECEK STRATEJİLERİ

İrfan İNAN¹
Mehmet Salih KAÇMAZ²
Savaş DEMİR³

Giriş

Tarım, insan uygarlığının temel taşlarından biri olarak, hayatta kalma, ekonomik kalkınma ve toplumsal ilerleme için gerekli gıda, lif ve kaynakları sağlamaktadır. Küresel nüfusun 2050 yılına kadar yaklaşık 10 milyara ulaşması beklenirken, gıda güvenliğini yani gıda arzının erişilebilirliği, kullanılabilirliği, yeterliliği ve istikrarı sağlamak, günümüzün en acil sorunlarından biri haline gelmiştir (FAO, 2025). Yeşil devrimden bu yana gıda sistemlerinde teknolojik ilerlemeler yaşanmış olmasına rağmen, mevcut küresel tarım ve gıda sistemleri dünyanın ihtiyaçlarını karşılayamamaktadır.

Gıda erişilebilirliği belirgin biçimde artmış olsa da, son kırk yılda açlık ve yetersiz beslenme yaşayan insan sayısı sabit kalmış; buna ek olarak obezite ve diyetle bağlı hastalıklar hızla artmıştır (FiBL, 2024)

¹ Yüksek Ziraat Mühendisi, Van Yüzüncü Yıl Üniversitesi, Hayvan Yetiştirme ve Islahı Anabilim Dalı, Van, Türkiye, Orcid: 0009-0007-0084-1394

² Arş. Gör. Dr., Van Yüzüncü Yıl Üniversitesi, Yemler ve Hayvan Besleme Anabilim Dalı, Van, Türkiye, Orcid: 0000-0003-3419-7342

³ Dr., Van Yüzüncü Yıl Üniversitesi, Tıbbi ve Aromatik Bitkiler Anabilim Dalı, Van, Türkiye, Orcid ID: 0000-0002-3795-8883

Konvansiyonel tarım sistemleri genellikle yüksek üretkenlik gösterir, artan küresel nüfusun beslenmesi için yüksek verimi güvence altına alır; ancak bu durum önemli çevresel maliyetlerle birlikte gelir. (Boschiero et al., 2023)Endüstriyel tarım uygulamaları herbisit-pestisit kullanımı, sentetik gübre uygulamaları, büyük ölçekli monokültürler ve toprak işleme dahil olmak üzere — atmosferdeki karbondioksit (CO₂) konsantrasyonlarının artmasına katkıda bulunmakta; küresel iklim değişikliğinin etkilerini şiddetlendirmekte; besin kirliliği ve toprak erozyonu yoluyla kritik su kaynaklarına zarar vermekte ve ekosistemlerde biyolojik çeşitliliği önemli ölçüde azaltmaktadır (Rosier, Knecht, Steinmetz ve ark., 2025).

Tarımsal sektör; doğal kaynakların bozulması, toprak verimliliğinin azalması, iklim değişkenliği ile artan sağlık ve gıda güvenliği sorunları gibi ciddi problemlerle karşı karşıyadır. Buna yanıt olarak sürdürülebilir tarım; bu birbiriyle bağlantılı sorunları ele alırken aynı zamanda çevresel korumayı, ekonomik dayanıklılığı ve sosyal refahı teşvik eden küresel bir öncelik hâline gelmiştir (Sandhu et al., 2025)Tarımın ve genel olarak insanlığın karşı karşıya olduğu sürdürülebilirlik sorunlarının büyüklüğü ve karmaşıklığı; dönüştürücü değişime ulaşmak için insan faaliyetlerinin farklı yönlerinde derin değişiklikler yapılması gerektiğini açıkça göstermektedir. (Barrios, Gemmill-Herren, Bicksler ve ark., 2020) Tarımın sürdürülebilirliğe geçişi; artan gıda talebi, gıda güvensizliği, iklim değişkenliği, biyolojik çeşitlilik kaybı ve gıda israfı gibi önemli engellerle karşı karşıyadır. Sürdürülebilir tarım; çevresel korumayı ve verimli gıda üretimini teşvik ederek gıda güvenliğini sağlamaktadır. sürdürülebilirliği sağlamanın yolu; yenilikçi ve etkin tarımsal uygulamaları benimsemekten geçmektedir. (Dass ve ark., 2025; Terán-Samaniego ve ark., 2025)

Sürdürülebilir tarıma ulaşmak ve üretim dengesini gelecek nesilleri tehlikeye atmadan sağlamak hem mümkündür hem de zorunluluktur. Sürdürülebilir kalkınmanın bileşenlerini anlamak ve doğru şekilde yönetmek mümkündür. Tarımı sürdürülebilir bir yola geçirmek; çevresel, sosyal, ekonomik ve teknik engellerin eşzamanlı olarak ele alınmasını gerektiren karmaşık bir çabadır (Kumari ve ark., 2024; Sandhu ve ark., 2025)Küresel tarım sürdürülebilir uygulamalar yoluyla dönüştürülmesi; çevresel, ekonomik ve sosyal zorlukların ele

alınması açısından acil bir öncelik hâline gelmiştir. Temel sonuçlar; hassas tarım, rejeneratif tarım, yenilenebilir enerji entegrasyonu ve döngüsel ekonomi modelleri gibi tekniklerin kaynak tüketimini önemli ölçüde azalttığını, verimliliği artırdığını ve sosyo-ekonomik eşitliği teşvik ettiğini göstermektedir. Sürdürülebilir tarım üç temel boyut içerir: ekonomik, çevresel ve sosyal. Sürdürülebilir tarım, son yirmi beş yıldır araştırmacıların odağında olmuş ve büyük ilgi çekmiştir (Bathaei & Štreimikienė, 2023; Doda ve ark., 2025).

2. Sürdürülebilir Tarım Kavramının Genel Göstergeleri

Küresel gıda üretiminin gelecekteki gıda talebini karşılamak için iki katına çıkacağı öngörülürken, üretkenliği çevresel sürdürülebilirlik ile dengeleyecek şekilde tarımsal sistemleri yeniden şekillendirmek kritik bir zorluktur. Tarımsal sistemlerin daha sürdürülebilir bir yöne evrilme gerekliliği geniş ölçüde kabul görmektedir. Tarım, sürdürülebilirlik dönüşümleri (sustainability transitions) çerçevesine yerleştirildiğinde odak neredeyse tamamen orta veya yüksek gelirli bağlamlardaki endüstriyel tarım üzerine yoğunlaşmakta; dolaylı olarak, dönüştürülmesi gereken mevcut (ve sorunlu) rejimin büyük ölçekli, yüksek düzeyde mekanize edilmiş tarım olduğu varsayılmaktadır (Touch et al., 2025; Wineman, 2025). Günümüzde dünya nüfusu benzeri görülmemiş bir hızla artmakta ve bu durum gıda üretim sistemleri üzerinde büyük bir baskı oluşturmaktadır. iklim değişikliği tarımı önemli ölçüde etkilediğinden, konvansiyonel tarıma yönelik incelemeler artmakta ve iklim-akıllı tarım, rejeneratif veya korumacı tarım, organik tarım, permakültür ve agroforestri gibi çeşitli sürdürülebilir tarım kavramları ortaya çıkmaktadır (Hussain et al., 2025; Uszkai, 2025). Sürdürülebilir tarımın dört evrensel ilkesine dönüştürülmüştür: entegre yönetim, dinamik denge, rejeneratif tasarım ve sosyal gelişim. Tüm bu ilkeler birbiriyle iç içedir, birbirine bağımlıdır ve bir bütün olarak ele alınmalıdır. Sürdürülebilir bir gıda

sistemi; sağlıklı ve besleyici gıdaların üretimini desteklemeli ve çiftçiler ile hayvancılık üreticileri için ekonomik sürdürülebilirliği sağlamalıdır. Aynı zamanda toprak, su, biyo çeşitlilik ve iklim üzerindeki olumsuz çevresel etkileri azaltmalı ve araziye, tarımsal kaynaklara ve gıdaya adil ve kapsayıcı erişimi teşvik etmelidir (Trigo et al., 2021; Varyvoda ve ark., 2025).

Tablo 1. Sürdürülebilir Tarım Göstergeleri.

Alan	Gösterge	Sürdürülebilir Tarım
Genel Kavram	Tanım	Tarımsal verimliliği artırırken doğal sermayeyi korumayı hedefler; kaynak kullanımında verimlilik ve yoğunluk odaklıdır; bugünün ihtiyaçlarını karşılarken gelecek nesilleri tehlikeye atmama ilkesine dayanır.
Temel Aktörler	Kimler?	Hükümetler, özel sektör (tohum, gübre, kimya endüstrisi), araştırmacılar, kalkınma kurumları.
Vizyon	Amaçlar	Gıda ve beslenme güvenliği, yoksulluğun azaltılması, çevresel–sosyal–ekonomik sürdürülebilirlik; geleneksel endüstriyel yoğunlaştırmaya alternatif.
Bilimsel Yaklaşım	GM teknolojisi	GDO’ya tolerans olabilir.
Eleştiriler	Muhalif görüşler	“Konvansiyonel endüstriyel tarımın devamı” olarak eleştirilebilir.
Çevresel Boyut	Arazi Kullanımı	“Arazi ayırma” – yoğun üretim + biyoçeşitlilik için ayrı alanlar.
	Alan dizilimi	Tek ürün (monokültür).
	Peyzaj	Alan genişletmek yerine yoğunluk ile çevresel zararı azaltma.

Alan	Gösterge	Sürdürülebilir Tarım
Tarım uygulamaları	Uygulama tarzı	İyileştirilmiş çeşitler + iyi tarım uygulamaları kombinasyonu.
Sosyal	Bilgi üretimi	Yerel + uzman bilgi birlikte.
	Çiftçi profili	Büyük ölçekli çiftçiler.
	Geçim desteği	Şirketler ve büyük üretici ortakları.
Ekonomik	Verim tanımı	Verim açığı / potansiyel verim açığı.
	Tohum sistemi	Endüstriyel dış kaynaklı tohum.
	Girdi kullanımı	Yüksek dış girdili (yüksek maliyet).

Kaynak: Mockshell ve Kamanda, 2018; Terán-Samaniego ve ark., 2025

3. Sürdürülebilir Tarımın İlkeleri ve Dünyada Uygulanan Sürdürülebilir Tarım Sistemleri

Sürdürülebilir tarım 3 genel ilke üzerine gelişmektedir, bunlar ekolojik, ekonomik ve sosyal ilkelerdir.

1) Ekolojik İlke

Sürdürülebilir tarım EKOLOJİK kalitenin korunmasını, doğal kaynakların verimli kullanımını ve biyoçeşitliliğin desteklenmesini gerektirir (Terán-Samaniego ve ark., 2025; Trigo ve ark., 2021).

2) Ekonomik İlke

Ekonomik sürdürülebilirlik; çiftliklerin uzun vadeli kârlılığı, piyasa risklerine dayanıklılığı ve üretici gelirinin iyileştirilmesi ile ilişkilidir (Bathaei & Štreimikienė, 2023; Saikanth ve ark., 2023).

3) Sosyal İlke

Sosyal sürdürülebilirlik; çiftçilerin refahının artması, adil çalışma koşulları sağlanması, kırsal toplulukların güçlenmesi adil kaynak paylaşımı ve gıda güvenliğine katkı ile tanımlanır (Sandhu ve ark., 2025; Hussain ve ark., 2025).

4. Dünyada Sürdürülebilir Tarım Sistemlerinin Sınıflandırılması ve Karşılaştırılması

- İklim Akıllı Tarım
- Organik Tarım
- Biyodinamik Tarım
- Entegre Tarım Sistemleri
- Entegre Besin Yönetimi
- Yer Özeline Dayalı Ürün Yönetimi / Hassas Tarım
- Tarım Orman Sistemleri (Agroforestry)
- Doğal Tarım
- Rejeneratif Tarım
- Karbon Tarımı
- Doğa Temelli Tarım
- Permakültür
- Agroekoloji
- Alternatif Gıda Ağları (Kumari ve ark 2024; Finizola e Silva ve ark 2024).

Tablo 2. Sürdürülebilir Tarım sistemlerinin karşılaştırılması

Sürdürülebilir Modelleri	Tarım	Sürdürülebilir Agro-gıda Sistemleri								
		Rejeneratif Tarım	İklim Tarım	Akıllı Karbon Tarımı	Yakalama Doğa Çözümler	Temelli	Alternatif Gıda Ağları	Permakültür	Agroekoloji	
Ekolojik Sürdürülebilirlik										
Toprak Sağlığı	++	+++		++		++	+++	+	+++	+++
Biyoçeşitlilik	++	++		+		+	+++	++	+++	+++
Dış Girdi Azaltımı	++	++		+		+	++	+	+++	++
İklim Dayanıklılığı	+	++		++		++	++	+	+++	+++
Ekonomik Sürdürülebilirlik										
Ekonomik Uygulanabilirlik	++	++		+		+	+	+++	+++	+++
Piyasa Dayanıklılığı	+	++		+		+	++	+++	+++	+++
Yerel Gıda Ekonomileri	+	++		+		+	+	+++	++	++
Sosyal Sürdürülebilirlik										
Gıda Adaleti ve Eşitlik	++	+		+		+	+	+++	++	+++
Geleneksel Bilgi	++	++		+		+	++	++	+++	+++
Topluluk Katılımı	++	+		+		+	+	+++	+++	+++
Üretici – Tüketici İlişkisi	+	+		+		+	+	+++	+++	+++

Kaynak: Zhang, 2024

Not: “+” işaretlerinin sayısı, her yaklaşımın ilgili sürdürülebilirlik boyutuna verdiği önem derecesini ifade eder.

5. Sürdürülebilir tarım sistemlerinin etkileri

Tarım sektörü, hassas tarım ve geliştirilmiş tedarik zinciri yönetimi gibi yeni teknolojik ilerlemelerin ortaya çıkmasıyla birlikte önemli bir büyüme için hazır durumdadır. Sürdürülebilir Tarım; ekosistem sağlığını yeniden tesis etmek, iklim değişikliğinin etkilerini hafifletmek ve hızla büyüyen küresel nüfus için besin açısından zengin gıda üretmek adına güçlü bir çerçeve sunmaktadır; Çiftçiler, politika yapıcılar, sağlık profesyonelleri ve tüketiciler gibi çoklu paydaşların iş birliği; yenileyici tarımı kenar uygulamalardan ana akım uygulamaya taşıyacak elverişli ortamın oluşturulması açısından kritik bir rol oynamaktadır (Gamage ve ark., 2024; Rosier, Knecht, Steinmetz ve ark., 2025).

Sürdürülebilir tarım; çevre dostu, ekonomik açıdan uygulanabilir ve sosyal açıdan adil uygulamaları teşvik etmektedir. Bu; hassas tarım teknolojileri, daha yüksek verim ve hastalık direnci için genetik olarak iyileştirilmiş ürünlerin kullanımı ve tarım uygulamalarına yenilenebilir enerji kaynaklarının entegrasyonu gibi gelişmiş teknolojilerin uygulanmasını içermektedir. Sürdürülebilir tarım aynı zamanda ekolojik dengeyi korurken gıda üretimini sürdürmek amacıyla yerel kaynakların ve geleneksel bilginin kullanımını desteklemektedir (Saikanth ve ark., 2023).

Tablo 3. Sürdürülebilir Tarım Uygulamalarının Etkileri

Bulgular		Açıklama
Sürdürülebilir Uygulamaların Benimsenmesi		Organik tarım, agroforestry, hassas tarım ve rejeneratif yöntemler; kimyasal girdilerin azaltılması, biyolojik çeşitliliğin korunması ve toprak sağlığının iyileştirilmesi.
Gıda Güvenliğine Katkı		Ürün verimliliği ve çeşitliliğinin artması, toprak sağlığının iyileştirilmesi, kaynakların daha verimli kullanımı ve toplumların taze gıdaya erişiminin kolaylaşması.
Çevresel Faydalar		Toprak bozulmasının, su kirliliğinin ve biyolojik çeşitlilik kaybının azalması; karbon tutumu ve ekosistem sağlığının gelişmesi.
Karşılaşılan Zorluklar		Yüksek başlangıç maliyetleri, sınırlı teknik bilgi, pazara erişim sorunları ve yetersiz politika desteği.
Devlet Politikaları ve Toplumsal Katılım		Destekleyici politikalar, kooperatifler, çiftçi pazarları ve bilgi paylaşım ağları sürdürülebilir uygulamaların benimsenmesini kolaylaştırır.
Başarı Ölçütleri ve Uzun Vadeli Uygulanabilirlik		Toprak sağlığı, biyolojik çeşitlilik, ekonomik sürdürülebilirlik ve iklim değişikliğine karşı dayanıklılık ile ölçülür.
İklim Dayanıklılığı		Kuraklık ve aşırı hava olaylarına karşı direnç; gıda güvenliğini korumada kritik öneme sahiptir.

Kaynak: Richard, 2024

6. Sürdürülebilir tarıma geçişte sorunlar ve çözümler

Sürdürülebilir tarıma ulaşmak ve üretim dengesini gelecek nesilleri tehlikeye atmadan sağlamak hem mümkündür hem de zorunluluktur. Sürdürülebilir kalkınmanın bileşenlerini anlamak ve doğru şekilde yönetmek mümkündür. Hızla artan dünya nüfusunun ihtiyaçlarını karşılayabilmek için gelişmiş agronomik uygulamaların, çevresel fizyolojinin ve etkili bitki beslemenin entegre edilmesi gerekmektedir. Temel amaç, yeterli miktarda gıda üretirken uzun vadeli ekolojik sağlığın korunması ve çevresel etkinin azaltılmasıdır (Kumari ve ark., 2024).

Tarımın sürdürülebilirliğini desteklemek için çok sayıda teknik bulunmaktadır. Ancak bu yenilikçi çözümlerin benimsenmesi; teknolojik fırsatların daha güçlü kullanımını engelleyen çoklu zorluklarla karşı karşıyadır. Bu tür sınırlamalar ekonomik, sosyal ve yönetsel boyutlara da sahiptir. En yaygın engeller arasında; yüksek yatırım maliyetleri, yenilik yapma isteksizliği, sosyal farkındalık / kabul eksikliği ve katı hukuki çerçeveler birçok vakada dile getirilmiştir (Boros ve ark., 2025).

Tarımın sürdürülebilirliğe geçişi; artan gıda talebi, gıda güvensizliği, iklim değişkenliği, biyolojik çeşitlilik kaybı ve gıda israfı gibi önemli engellerle karşı karşıyadır. Sürdürülebilir tarım; çevresel korumayı ve verimli gıda üretimini teşvik ederek gıda güvenliğini sağlamaktadır (Terán-Samaniego ve ark., 2025).

Bulgular, tarımsal çeşitlendirme, ürün değerinin artırılması ve üretim verimliliğinin, çiftçilerin ekonomik refahını artırabilen temel stratejiler olduğunu göstermektedir. Ekolojik açıdan, toprak ve su koruma uygulamaları, biyoçeşitlilik yönetimi ve kimyasal kullanımının azaltılması, çevresel sürdürülebilirlik için kritik öneme sahiptir. Sosyal açıdan ise sürdürülebilir tarım; çiftçi refahı, toplumsal güçlenme ve halk sağlığı üzerinde olumlu etkiler yaratmaktadır. Politika desteği, teknolojiye ve pazara erişim ile kapsamlı eğitim ve öğretim faaliyetleri, sürdürülebilir tarımın uygulanmasında kilit faktörlerdir (Kamakaula, 2024).

Tablo 4. *Sürdürülebilir gıda sistemlerini kolaylaştırmaya yönelik fırsatların özeti*

Faktörler	Fırsatlar
Ekonomik faktörler	1. Agroekoloji / organik (AE/O) yaklaşımını önceleyen uzun vadeli finansman modelleri oluşturarak sürdürülebilir gıda sistemlerine geçişi hızlandırmak. 2. AE/O ürünleri için adil fiyatlandırmayı desteklemek ve tüketicinin gıda ile çiftçi arasındaki bağlantısını güçlendirmek için değer zinciri gelişimini önceliklendirmek.
Kaynak faktörleri	3. AE/O girdilerine ve girdi sübvansiyonlarına adil erişimi güvence altına almak. 4. Gençler için kırsal alanları daha cazip hâle getirmek ve manuel iş gücüne bağımlılığı azaltmak için uygun ölçekli mekanizasyon ve dijitalleşmeye yatırım yapmak. 5. Tropik bölgelerde AE/O çiftçileri için arazi

Faktörler	Fırsatlar
Bilgi faktörleri	mülkiyet güvencesini iyileştirmeye yönelik politikaları reforme etmek.
	6. Kapasite geliştirme yoluyla agronomik ve ekonomik performansı, sosyal sermayeyi ve dayanıklılığı artırmak. Bu; çiftçi örgütlerini güçlendirerek ve yayım hizmetlerini iyileştirerek yapılabilir.
	7. Çiftçilere ve danışmanlara dijital araçlar dahil olmak üzere uyarlanmış ve yerel-bağlama özgü bilgiye erişim sağlamak.
Sosyal ve kültürel faktörler	8. Bilginin ortak üretimini ve değişimini kolaylaştırmak için disiplinlerarası ve katılımcı eğitim ile araştırmayı ilerletmek; böylece yerel en uygun çözümleri belirlemek, yaygınlaştırmak ve ölçek büyütmek.
	9. Tüketicileri gıda okuryazarlığını geliştirici programlara dahil etmek ve destekleyici politikaları uygulamak.
Yönetişim faktörleri	10. Bilgili, koordineli ve katılımcı yönetişimi savunabilmeleri için karar vericileri ve politika yapıcılarını güçlendirmek.
	11. Akıllı teşvikler ve destekleyici politikalar aracılığıyla AE/O tarımını desteklemek.

Kaynak: FiBL, 2024

Tablo. 5 Sürdürülebilir Tarımda Zorluklar ve Fırsatlar

Zorluklar	Fırsat /Çözüm	Açıklama
İklim Değişikliği	Rejeneratif Tarım	Toprak sağlığını iyileştirir, karbon tutumunu artırır ve iklim değişikliğine karşı direnç kazandırır.
Biyoçeşitliliği Kaybı	Agroekoloji	Biyoçeşitliliği destekler, toprak sağlığını iyileştirir ve doğal kaynakları korur.
Toprak Bozulması	Organik Tarım	Sentetik pestisit ve gübreleri azaltır, toprak organik maddesini ve biyolojik aktivitesini artırır.
Su Kıtlığı	Hassas Tarım	Sensörler ve akıllı sistemlerle sulama optimize edilerek su kullanımı azaltılır.
Kırsal Toplulukların Erozyonu	Döngüsel Ekonomi	Atıkları azaltır, kaynak verimliliğini artırır ve çiftçiler için yeni gelir kaynakları yaratır.

Kaynak: Hiywotu, 2025

7. Sürdürülebilir Tarımın Gelişmesinin Önemi ve Gelecek Senaryoları

Avrupa Komisyonu’nun şubat 2025’te yayımlanan tarım ve gıdaya ilişkin vizyon belgesi, tarım ve gıda sektörünün uzun vadeli rekabet gücünü ve sürdürülebilirliğini güvence altına almayı amaçlamaktadır.

Belge dört ana bölümden oluşmaktadır ve gelecek senaryolarını kapsamaktadır.

- a) Herkes için erişilebilir gıda ile tarımı cazip bir sektör hâline getirmek,
- b) Rekabetçi ve dayanıklı bir sektör oluşturmak,
- c) Sürdürülebilir, gıda güvenliğini destekleyen ve geleceğe uyumlu bir sektör yaratmak,
- d) Adil yaşam ve çalışma koşullarına sahip, canlı ve dinamik bir tarım sektörü inşa etmek

Fırtınalar (Storms) senaryosunda küresel işbirliği çöker; kıtlık, kutuplaşma ve bloklar arasında düşmanlık artar. Bu nedenle döngüsellik ve sera gazı azaltımı gibi sürdürülebilirlik ifadeleri daha az uygulanabilir; buna karşılık yerel gıda sistemlerini destekleme ve dış bağımlılığı azaltma ifadesi “özerklik” vurgusuyla daha uyumludur.

Son Oyun (Endgame) senaryosunda ekonomik büyüme ve rekabet ön plandadır; eşitsizlik ve çevresel bozulma artar. Bu nedenle sürdürülebilirlik ve yerel gıda sistemleri zayıf performans gösterirken, hassas tarım ve dijitalleşme gibi teknoloji odaklı ifadeler daha uygulanabilir görünür ancak sosyal ve çevresel sorunları çözmez.

Mücadele Eden Sinerjiler (Struggling synergies) senaryosunda iklim eylemi ve teknolojik yenilik güçlüdür; ancak diğer sürdürülebilirlik boyutları daha zayıftır. Bu nedenle iklim eylemine dönük ifadeler daha uygulanabilirken sosyal adalet zayıf kalır. Yerel gıda sistemleri karbon azaltımı açısından olumlu olabilir fakat küreselleşmiş piyasalarda öncelik olmayabilir.

Zıt Görüşler (Opposing views) senaryosunda sosyal eşitlik ve çevresel sürdürülebilirliğe dayalı “yenileyici ittifak” vardır. Bu nedenle sürdürülebilirlik, döngüsellik, yerel gıda sistemleri, çiftçi gelirlerinin iyileştirilmesi ve adil ticaret ifadeleri daha uygulanabilir görünmektedir. Genel olarak sürdürülebilir protein kaynakları, stratejik bağımlılıkların azaltılması ve basitleştirme–dijitalleşme en dayanıklı bileşenlerdir. Gıda etiketleme ve “işlevsel kırsal alanlar” ise daha sağlamlaştırılmalıdır. Çalışma, karmaşık sorunların politika tutarlılığı ve güçlü koordinasyon gerektirdiğini; bu nedenle daha tutarlı politikalar ve daha öngörüselleşmiş yönetişimin gerekli olduğunu göstermektedir (European Commission, 2025).

Bütün gelecek senaryolarda ‘*tarımın geleceği üzerinde*’ şekillenecek iklim değişikliğinin olumsuz etkileri sürdürülebilir tarımın ekonomik ekolojik ve sosyal boyutlarının gelişimi üzerinde belirleyici konumunu korumaktadır.

Sürdürülebilir tarım; Dünya nüfusunda hızlı artışa bağlı gelişen gıda talebi, ekolojik dengenin bozulması ile birlikte ortaya

ıkan iklim deęiřkenlięi, biyolojik eřitlilik kaybı gibi nemli engellerle karřı karřıyadır. Srdrlebilir tarım; evresel korumayı ve verimli gıda retimini teřvik ederek gıda gvenlięini saęlamaktadır. Organik tarım agroekolojik tarım Hassas tarım, rejeneratif tarım, yenilenebilir enerji entegrasyonu ve dngsel ekonomi modelleri gibi srdrlebilir tarım sistemleri kaynak tketimini azaltmakta, verimlilięi artırmakta ve sosyo-ekonomik eřitlięi desteklemektedir. Organik tarım, agroforestry, hassas tarım ve rejeneratif yntemler; kimyasal girdilerin azaltılması, biyolojik eřitlilięin korunması ve toprak saęlıęının iyileřtirilmesine katkı sunmaktadır. Politika desteęi, teknolojiye eriřim ve kapsamlı eęitim faaliyetleri srdrlebilir tarımın uygulanmasında kilit faktrlerdir. Kresel tarımın geleceęini ekolojik ekonomik ve ekolojik parametrelerin btncl srdrlmesinde belirleyici olacaktır.

Avrupa komisyonunun belirledięi Tarımsal ilkeler ve gelecek senaryoları baz alındıęında srdrlebilir tarımın nemi kapsamı ve gelecek senaryosunu destekleyecek en byk kaynak olmaktadır.

SONU

Tarımda Yeřil devrimin geliřmesi ile birlikte Konvansiyonel tarım sistemleri rn artıřı yksek verim avantajına raęmen ekolojik dengenin bozulmasına baęlı ortaya ıkan toprak kirlilięi biyoeřitlilik kaybı, gıda rnlerinde besin kalitesinde azalma ve iklim deęiřiklięinin olumsuz etkileri srdrlebilir tarıma geiřin nemini zorunlu kılmaktadır. Srdrlebilir tarım evresel,

ekonomik ve sosyal boyutlarını büt nleřtirerek gıda sistemlerinin geleceęe uyumlu biimde yeniden tasarlanmasını hedeflemektedir. Bulgular; hassas tarım, rejeneratif tarım, agroekoloji, organik tarım, permak lt r, karbon tarımı ve agroforestry gibi sistemlerin; biyolojik eřitlilięi destekledięini, dıř girdileri azalttıęını, toprak saęlığını geliřtirdięini ve yerel ekonomileri g lendirdięini g stermektedir. Bu yaklařımların benimsenmesini kısıtlayan temel engeller arasında y ksek maliyetler, bilgi eksiklięi, sınırlı politika desteęi ve pazara eriřim sorunları yer almaktadır. AB'nin 2025 tarım ve gelecek vizyonu da dahil olmak  zere uluslararası politika ereveleri; gıda g venlięi, yerel gıda sistemleri, dayanıklılık, dijitalleřme, deęer zinciri iyileřtirme ve adil gelir paylařımını ana bileřenler olarak s rd r lebilir tarımın  nemli ilkelerini savunmaktadır. S rd r lebilir tarım, Hem iklim dayanıklılıęının artırılması, ekosistem saęlığının korunması hem de gelecek nesiller iin g venli gıdaya eriřimin s rd r lebilir biimde saęlanması iin stratejik bir gereklilik olarak ortaya ıkmaktadır. Bu alıřmada, artan k resel n fus, iklim deęiřkenlięi, ekolojik bozulma ve gıda g venlięinin saęlanması ekseninde ekolojik ekonomik ve sosyal ilkeler kapsamında s rd r lebilir tarıma geiřin  nemini ortaya ıkarmaktadır.

Kaynakça

Bathaei, A., & Štreimikienė, D. (2023). *A systematic review of agricultural sustainability indicators*. Agriculture, 13, 241. <https://doi.org/10.3390/agriculture13020241>

Boros, A., Szólik, E., Desalegn, G., & Tózsér, D. (2025). A systematic review of opportunities and limitations of innovative practices in sustainable agriculture. *Agronomy*, 15(1), 76. <https://doi.org/10.3390/agronomy15010076>

Boschiero, M., De Laurentiis, V., Caldeira, C., & Sala, S. (2023). *Comparison of organic and conventional cropping systems: A systematic review of life cycle assessment studies*. Environmental Impact Assessment Review, 102, 107187. <https://doi.org/10.1016/j.eiar.2023.107187>

Dass, A., San, A. A., Jinger, D., Kumari, K., Singh, A., Singh, T., Poonam, A., Paramesh, V., Gupta, G., Rajanna, G. A., Kaur, R., Shekhawat, K., Rathore, S. S., Meena, V. S., Sachin, K. S., Devi, A. D., Nithinkumar, K., Gautam, M. K., Kushwaha, H., Mani, I., & Meena, S. K. (2025). Sustainable intensification strategies: Balancing productivity, quality, and profitability in agri-food systems with resource optimization. *Frontiers in Agronomy*, 7, 1611739. <https://doi.org/10.3389/fagro.2025.1611739>

Doda, H., Sharma, A., & Thakur, N. (2025). *A systematic review on sustainable practices transforming global agribusiness*. Frontiers in Sustainable Food Systems, 9, 1566708. <https://doi.org/10.3389/fsufs.2025.1566708>

Edmundo Barrios , Barbara Gemmill-Herren , Abram Bicksler , Emma Siliprandi , Ronnie Brathwaite , Soren Moller , Caterina Batello & Pablo Tittonell (2020) The 10 Elements of Agroecology: enabling transitions towards sustainable agriculture

and food systems through visual narratives, *Ecosystems and People*, 16:1, 230-247, DOI:10.1080/26395916.2020.1808705

European Commission. (2025, February 19). *A vision for agriculture and food: Shaping together an attractive farming and agri-food sector for future generations (COM(2025) 32 final)*. Publications Office of the European Union. https://agriculture.ec.europa.eu/overview-vision-agriculture-food/vision-agriculture-and-food_en

FAO. (2025). *Food and agriculture organization of the United Nations*. <https://www.fao.org>

FiBL. (2024). *Cultivating change with agroecology and organic agriculture in the tropics: Bridging science and policy for sustainable production systems* (Policy dossier No. 2000P). Research Institute of Organic Agriculture FiBL. <https://doi.org/10.5281/zenodo.10521540>

Finizola e Silva, M., Van Schoubroeck, S., Cools, J., & Van Passel, S. (2024). *A systematic review identifying the drivers and barriers to the adoption of climate-smart agriculture by smallholder farmers in Africa*. *Frontiers in Environmental Economics*, 3, 1356335. <https://doi.org/10.3389/frevc.2024.1356335>

Gamage, A., Gangahagedara, R., Subasinghe, S., Gamage, J., Guruge, C., Senaratne, S., Randika, T., Rathnayake, C., Hameed, Z., Madhujith, T., & Merah, O. (2024). Advancing sustainability: The impact of emerging technologies in agriculture. *Current Plant Biology*, 40, 100420. <https://doi.org/10.1016/j.cpb.2024.100420>

Hiywotu, A. M. (2025). Advancing sustainable agriculture for Goal 2: Zero hunger – A comprehensive overview of practices, policies, and technologies. *Agroecology and Sustainable Food*

Systems, 49(7), 1027–10
<https://doi.org/10.1080/21683565.2025.2451344>

Hussain, M. A., Li, L., Kalu, A., Wu, X., & Naumovski, N. (2025). *Sustainable food security and nutritional challenges*. *Sustainability*, 17, 874. <https://doi.org/10.3390/su17030874>

Kamakaula, Y. (2024). *Sustainable agriculture practices: Economic, ecological, and social approaches to enhance farmer welfare and environmental sustainability*. *West Science Nature and Technology*, 2(2), 47–54. <https://wsj.westscience-press.com/index.php/wsnt>

Kumari, N., Pandey, A. K., Singh, A. K., & Singh, A. (2024). Sustainable agriculture: Balancing productivity and environmental stewardship for future generations. *Journal of Scientific Research and Reports*, 30(8), 629–639. <https://doi.org/10.9734/jsrr/2024/v30i82284>

Mockshell, J., & Kamanda, J. (2018). *Beyond the agroecological and sustainable agricultural intensification debate: Is blended sustainability the way forward?* *International Journal of Agricultural Sustainability*, 16, 127–149. <https://doi.org/10.1080/14735903.2018.1448042>.

Richard, I. E. (2024). The impact of sustainable agriculture practices on food security and environmental conservation. *International Journal of Development Research*, 14(12), 67174–67196.

Rosier, C. L., Knecht, A., Steinmetz, J. S., Weckle, A., Bloedorn, K., & Meyer, E. (2025). *From soil to health: Advancing regenerative agriculture for improved food quality and nutrition security*. *Frontiers in Nutrition*, 12, 1638507. <https://doi.org/10.3389/fnut.2025.1638507>

Saikanth, D. R. K., Supriya, B. V., Singh, B. V., & Rai, A. K. (2023). *Advancing sustainable agriculture: A comprehensive review for optimizing food production and environmental conservation*. *International Journal of Plant & Soil Science*, 35(16), 417–425. <https://doi.org/10.9734/IJPSS/2023/v35i163169>

Sandhu, S., Kaur, H., & Pateer, S. (2025). *A conceptual review of sustainable agriculture approaches and practices: Toward sustainable agricultural transitions*. *Economic Sciences*, 21(1). <https://doi.org/10.69889/haqs3r53>

Terán-Samaniego, K., Robles-Parra, J. M., Vargas-Arispuro, I., Martínez-Téllez, M. Á., Garza-Lagler, M. C., Félix-Gurrrola, D., Maycotte-de la Peña, M. L., Tafolla-Arellano, J. C., García-Figueroa, J. A., & Espinoza-López, P. C. (2025). Agroecology and sustainable agriculture: Conceptual challenges and opportunities—A systematic literature review. *Sustainability*, 17, 1805. <https://doi.org/10.3390/su17051805>

Terán-Samaniego, K., Robles-Parra, J. M., Vargas-Arispuro, I., Martínez-Téllez, M. Á., Garza-Lagler, M. C., Félix-Gurrrola, D., Maycotte-de la Peña, M. L., Tafolla-Arellano, J. C., García-Figueroa, J. A., & Espinoza-López, P. C. (2025). *Agroecology and sustainable agriculture: Conceptual challenges and opportunities—A systematic literature review*. *Sustainability*, 17, 1805. <https://doi.org/10.3390/su17051805>

Touch, V., Utomo, A., Harrigan, N., Finlayson, C., McGregor, A., McKinnon, K., Tran, T. A., Bannan, L.-A., Tan, D. K. Y., Sophanara, P., Chay, P., Yous, S., Hainzer, K., & Cook, B. R. (2025). *Reshaping agricultural production systems: Trade-offs and implications for sustainable intensification and environment management*. *Agricultural Systems*, 230, 104484. <https://doi.org/10.1016/j.agsy.2025.104484>

Trigo, A., Marta-Costa, A., & Fragoso, R. (2021). *Principles of sustainable agriculture: Defining standardized reference points*. Sustainability, 13, 4086. <https://doi.org/10.3390/su13084086>

Uszkai, A. (2025). Sustainable urban food production with a special focus on permaculture from Hungarian perspectives / Macar perspektifinden permakültüre özel bir odaklanma ile sürdürülebilir kentsel gıda üretimi. *Planlama*, 2025(Suppl 1), 123–133. <https://doi.org/10.14744/planlama.2025.80847>

Varyvoda, Y., Thomson, A., & Bruno, J. (2025). *Factors influencing the adoption of sustainable agricultural practices in the U.S.: A social science literature review*. Sustainability, 17, 6925. <https://doi.org/10.3390/su17156925>

Wineman, A. (2025). *Agricultural transition processes and sustainability: A review with a focus on low-income settings*. Global Environmental Change Advances, 5, 100025. <https://doi.org/10.1016/j.gecadv.2025.100025>

BÖLÜM 4

VARYANS ANALİZLERİNDE EKSİK VERİ DOLDURMA YÖNTEMLERİ VE MODERN YAKLAŞIMLAR

HAMZA YALÇIN¹

Giriş

Bilimsel araştırmaların temel gayesi, evrendeki olaylar ve olgular arasındaki ilişkileri gözlemleyerek gerçeğe en yakın istatistiksel çıkarımlarda bulunmaktır. Ancak gerek deneysel gerekse gözlemsel tasarımlarda veri toplama süreci nadiren kusursuz işler. Laboratuvar ortamındaki cihaz arızalarından, klinik çalışmalarındaki katılımcı terklerine; anket uygulamalarındaki yanıtız bırakılan sorulardan, saha araştırmalarındaki ölçüm hatalarına kadar birçok faktör veri setlerinde boşluklar yaratır. İstatistiksel metodoloji literatüründe "eksik veri" (missing data) olarak adlandırılan bu problem, özellikle ortalama farklılıklarını ve faktör etkileşimlerini inceleyen Varyans Analizi (ANOVA), Kovaryans Analizi (ANCOVA) ve Çok Değişkenli Varyans Analizi (MANOVA) gibi karmaşık analitik

¹ Dr. Öğr. Üyesi, Harran Üniversitesi, Ziraat fakültesi, Zootehni Bölümü, Orcid: 0000-0003-0733-7821

modellerde arařtırmacıların en ok zorlandıęı teknik engellerden biridir (Baraldi & Enders, 2010; Dong & Peng, 2013).

Eksik verilerin bir veri setindeki varlıęı, yalnızca gözlem sayısının veya örneklem hacminin basit bir matematiksel azalması olarak değeriendirilemez. Eksikliklerin rastgele olmayan veya belirli bir örüntüye sahip biçimde ortaya çıkması, deney grupları arasındaki varyansın yapay olarak bozulmasına yol aar. Rubin (1976) tarafından temel istatistiksel erevesi izildięi üzere, eksik veriler uygun yöntemlerle yönetilmedięinde arařtırmanın istatistiksel gücü (statistical power) dramatik şekilde düşer, parametre tahminleri yanlı (biased) hale gelir ve en tehlikelisi, arařtırmanın Tip I hata oranları kontrolden ıkararak yanlış bilimsel sonuçlara varılmasına neden olabilir (Enders, 2022). Özellikle tekrarlı ölçümler (repeated measures) ieren tasarımlarda veya birden fazla baęımlı deęiřkenin eř zamanlı olarak değeriendirildięi MANOVA analizlerinde, tek bir hücredeki eksiklik bile tüm bir denek satırının geleneksel yazılımlar tarafından analizden dıřlanmasına yol aarak büyük bir bilgi kaybı yaratmaktadır (Tabachnick & Fidell, 2013).

Tarihsel sürece bakıldığında, 20. yüzyılın sonlarına kadar veri analiz yazılımlarının donanımsal sınırları ve algoritmik yetersizlikleri, eksik verilerle bařa ıkma arařtırmacıları genellikle pratik fakat oldukça kusurlu yöntemlere itmiştir. Bunların bařında, eksik veriye sahip gözlemlerin analizden tamamen ıkarılmasını öngören "liste bazında silme" (listwise deletion) ve eksik hücrelerin o deęiřkenin ortalamasıyla doldurulduęu "ortalama atama" (mean imputation) yöntemleri gelir (Allison, 2001). Ne var ki, istatistik bilimindeki kuramsal ilerlemeler ve bilgisayar teknolojilerindeki muazzam sıramalar, bu geleneksel yöntemlerin analiz sonuçları üzerindeki yıkıcı etkilerini net bir biçimde ortaya koymuştur (Schafer, 1997).

Bugün, 2020 ve sonrası dönemin akademik yayın standartlarına bakıldığında köklü bir paradigma deęiřimi yařandığı aıka

görülmektedir. Amerikan Psikoloji Birliği'nin yayımladığı APA 7. Sürüm kılavuzu ve tıp, psikoloji, ziraat gibi alanlardaki etki değeri yüksek (Q1/Q2) dergilerin veri analiz politikaları, geleneksel eksik veri yöntemlerini bilimsel geçerlilik açısından yetersiz bulmaktadır (American Psychological Association, 2020). Modern bilimsel konsensüs, varyans analizlerindeki eksik verilerin basitçe silinmesini veya ortalama değerlerle maskelenmesini kesin bir dille reddetmektedir. Bunun yerine; Çoklu Atama (Multiple Imputation - MI), Tam Bilgi Maksimum Olabilirlik (Full Information Maximum Likelihood - FIML) ve son yıllarda hızla yükselen Makine Öğrenmesi (Machine Learning) tabanlı esnek atama algoritmaları, yeni dönemin altın standartları olarak kabul edilmiştir (Enders, 2022; van Buuren, 2018).

Bu bölümün temel amacı, ANOVA ve MANOVA gibi çok değişkenli tasarımlarda araştırmacıların karşılaştığı eksik veri problemini salt matematiksel bir sorun olmaktan çıkarıp, güncel literatür ışığında anlaşılır ve pratik bir yaklaşımla ele almaktır. Bu doğrultuda; eksik verinin arkasında yatan teorik mekanizmalar irdelenecek, geleneksel yöntemlerin varyans analizi üzerindeki bozucu etkileri eleştirel bir dille tartışılacak ve nihayetinde 2020-2026 dönemi modern istatistik dünyasının benimsediği ileri atama algoritmaları detaylı biçimde incelenecektir.

Eksik Veri Mekanizmaları: Güncel Perspektif

Araştırmacıların eksik verilerin analitik süreçlerde nasıl bir sapmaya yol açacağını tam olarak kavrayabilmeleri için, öncelikle verinin arka planda hangi motivasyonla veya hangi dinamiklerle kaybolduğunu teşhis etmeleri gerekmektedir. İstatistiksel literatürde, eksik veri davranışları matematiksel olarak "eksik veri mekanizmaları" (missing data mechanisms) adı verilen kavramsal bir çerçeveye oturtulmuştur. Donald B. Rubin'in (1976) öncülük ettiği ve günümüzde de evrensel olarak kabul gören bu

sınıflandırma; verinin doğasını anlamamızı sağlayan üç temel kategoriden oluşur: Tamamen Rastgele Kayıp (MCAR), Rastgele Kayıp (MAR) ve Rastgele Olmayan Kayıp (MNAR) (Little & Rubin, 2019; Schafer, 1997).

Tamamen Rastgele Kayıp (Missing Completely at Random - MCAR): Eksik verinin oluşma olasılığının, veri setindeki hem gözlemlenen hem de gözlemlenemeyen (eksik olan) diğer tüm değerlerden bağımsız gerçekleştiği en ideal ancak gerçekte en nadir rastlanan senaryodur. Bu durumu bir laboratuvar deneyinde rastgele birkaç numune tüpünün kırılması veya veri girişini yapan araştırmacının kazara bazı hücreleri boş bırakması şeklinde somutlaştırabiliriz. Veri MCAR yapısında olduğunda, elinizde kalan eksik gözlemler veri seti, orijinal popülasyonun hala rastgele bir alt kümesini temsil eder. Dolayısıyla, varyans analizi (ANOVA) yapıldığında elde edilecek parametre tahminleri (grup ortalamaları vb.) teknik olarak yansız (unbiased) olmaya devam edecektir. Ancak, gözlem sayısındaki düşüş nedeniyle analizdeki istatistiksel güçte (power) mutlak bir kayıp yaşanır. MCAR varsayımının doğruluğu pratikte *Little'in MCAR Testi* gibi istatistiksel araçlarla sınanabilmektedir (Little, 1988).

Rastgele Kayıp (Missing at Random - MAR): 2020 sonrası literatürde, modern veri setlerindeki eksikliklerin büyük çoğunluğunun uyduğu veya uyması gerektiği kabul edilen temel mekanizmadır (Enders, 2022). MAR durumunda, bir değişkendeki eksikliğin ortaya çıkma olasılığı o değişkenin kendi alacağı değerden değil, veri setindeki *başka bir gözlemlenen değişkenden* kaynaklanır. Örneğin, bir ziraat veya hayvan besleme çalışmasında, bir grup hayvanın ağırlık ölçümlerindeki eksikliğin, doğrudan ağırlığın kendisiyle değil de hayvanın cinsiyeti veya uygulanan diyet türü (zaten kayda alınmış değişkenler) ile ilişkili olması durumu bir MAR mekanizmasıdır. Gözlemsel bir anket örneğinde ise, erkek katılımcıların kadınlara kıyasla depresyon veya gelir düzeyi

sorularını daha sık boş bırakmaları MAR yapısına işaret eder (Dong & Peng, 2013). Eğer bu tür bir veri setinde varyans analizi yapılacaksa, eksikliği açıklayan bu "gözlemlenen değişkenlerin" mutlaka çoklu atama modeline dahil edilmesi gerekmektedir. Aksi takdirde, gruplar arasındaki farklar yanlış hesaplanarak MAR yapısı MNAR'a dönüşür ve analiz ciddi sapmalar verir (Collins & ark., 2001).

Rastgele Olmayan Kayıp (Missing Not at Random - MNAR):

Eksik veri analizi dünyasının en karmaşık ve çözümü en zorlu senaryosudur. MNAR durumunda, bir verinin eksik olma olasılığı doğrudan o değişkenin *kendi (ancak gözlemlenemeyen) değeriyle* ilgilidir (Baraldi & Enders, 2010). Su kalitesinin ölçüldüğü bir çevre analizinde, ölçüm cihazının sadece belli bir kirlilik eşliğinin altındaki değerleri (detection limit) okuyamayıp o verileri "eksik" üretmesi buna klasik bir örnektir. Benzer şekilde, bir hayvan refahı değerlendirme çalışmasında (Yalçın & ark., 2021) en yüksek stres seviyesine sahip canlıların ölçüm sürecinden fizyolojik nedenlerle düşmesi veya depresyon seviyesi en yüksek olan hastaların anketi cevaplamayı reddetmesi MNAR mekanizmasıdır. MNAR yapısında, eksik veriyi veri setindeki diğer değişkenlerle açıklamak mümkün olmadığından, standart MICE veya FIML algoritmaları tek başlarına yetersiz kalır. Bu gibi durumlarda araştırmacıların karmaşık duyarlılık analizlerine (sensitivity analysis) veya pattern-mixture modellerine yönelmesi bir zorunluluktur.

Literatürde Artık Önerilmeyen Geleneksel Yaklaşımlar

İstatistik biliminde bilgisayar tabanlı yazılımların henüz tam olgunlaşmadığı dönemlerde, araştırmacılar varyans analizlerini tamamlayabilmek için genellikle veriyi analiz edilebilir bir boyuta indirgemeye yönelik "kolaycı" veya "silici" yöntemlere başvurmuştur. Ne var ki, son 20 yılın kuramsal literatürü ve modern bilgisayar simülasyonları, pratik görünen bu geleneksel yöntemlerin

analiz sonuçları üzerindeki yıkıcı etkilerini kesin bir dille kanıtlamıştır (Schafer, 1997). Bu bağlamda, güncel hakemli dergi politikalarının varyans tasarımlarında artık kesinlikle reddettiği geleneksel yaklaşımlar şunlardır:

Liste Bazında ve Çift Bazında Silme (Listwise / Pairwise Deletion): Liste bazında silme, veri setindeki herhangi bir değişkende tek bir eksik hücresi bulunan deneğin (satırın) analizden tamamen çıkarılmasını ifade eder (Allison, 2001). Geleneksel yazılımların varsayılan (default) tepkisi olan bu yöntem, sadece veri kusursuz bir şekilde MCAR olduğunda yansız sonuçlar üretmektedir. Gerçekte çoğu verinin MAR yapısında olduğu düşünüldüğünde, sadece tam veriye sahip gözlemlerle ANOVA veya MANOVA yapmak, araştırmanın örneklem profilini bozar ve gruplar arası ortalamaları sapmalı (biased) hale getirir (Graham, 2009). Bununla birlikte, liste bazında silme çok değişkenli analizlerde devasa veri kayıplarına yol açar; bu da istatistiksel gücü öylesine düşürür ki, gerçekte var olan anlamlı bir faktör etkileşiminin tespit edilememesine (Tip II Hata) zemin hazırlar (Maxwell & Delaney, 2004). Çift bazında silme yöntemi ise farklı değişken analizlerinde farklı alt örneklemeler kullanarak, MANOVA’da ihtiyaç duyulan varyans-kovaryans matrisinin matematiksel bütünlüğünü bozar ve hesaplanamaz pozitif tanımlı (non-positive definite) matris hatalarına sebep olur (Enders, 2022).

Tekil Atama Yöntemleri (Ortalama, Medyan veya Basit Regresyon Ataması): Veri kaybını önlemek amacıyla, eksik olan hücrelerin o değişkene ait aritmetik ortalama, medyan veya basit bir doğrusal regresyon denklemi ile elde edilen tek bir sabit değerle doldurulması işlemidir. İlk bakışta veri setini koruduğu için mantıklı gibi görünse de, istatistiksel açıdan büyük bir yanılgı içerir. Ortalama atama yöntemi, değişkenin doğasında var olan doğal dalgalanmayı (varyansı) suni olarak bastırır ve ortalamaya doğru bir yığılma yaratarak değişkenin standart sapmasını yapay bir şekilde

küçültür (Little & Rubin, 2019). Varyans analizinde (ANOVA), grup varyanslarının ve hata terimlerinin olduğundan çok daha küçük tahmin edilmesi, hesaplanan F istatistiğinin şişmesine neden olur. Bu durum, araştırmacıyı Tip I hata tuzağına düşürür; yani gerçekte anlamsız olan bir grup farklılığının "istatistiksel olarak anlamlı" bulunması riskini inanılmaz ölçüde artırır (Field, 2013).

Bunlara ek olarak, eksik veri doldurma süreçlerinin veri setinde barınabilecek aykırı değerlerden (outliers) ne denli etkilendiği de dikkate alınması gereken bir diğer modern eleştiridir. Klasik atama algoritmaları ekstrem değerlere karşı oldukça kırılgandır. Bu nedenle, eksik veri atamalarından hemen önce veya atama algoritmasının içine entegre edilecek şekilde sağlam (robust) normalleştirme tekniklerinin kullanılması, analizin güvenilirliğini dramatik şekilde yükseltmektedir (Yalçın & Öztürk, 2026). Klasik yöntemlerin bahsi geçen bu kusurları, istatistiksel literatürde belirsizliği (uncertainty) ve rastgeleliği modele entegre eden stokastik modern yaklaşımların (Çoklu Atama ve FIML) doğuşuna zemin hazırlamıştır.

Çoklu Atama (Multiple Imputation - MI) ve MICE: Yeni Altın Standart

Geleneksel ve tekil atama yöntemlerinin sebep olduğu varyans bozulmalarını aşmak üzere geliştirilen ve modern istatistik dünyasında altın standart olarak kabul gören temel yaklaşım, Çoklu Atama (Multiple Imputation - MI) metodudur. Orijinal olarak Rubin (1987) tarafından formüle edilen bu yöntemin en büyük felsefi devrimi, eksik veriyi "gerçekte ne olabilirdi" düşüncesiyle tek bir kesin değere mahkum etmek yerine, istatistiksel bir belirsizliği (uncertainty) modelin içine entegre etmesidir. Çoklu atama işleminde eksik değerler rastgele hata terimleri barındıran stokastik denklemlerle doldurulur ve bu süreç defalarca (genellikle 5 ila 50 iterasyon arasında) tekrarlanır. Bunun sonucunda, birbirinden çok

ufak farklarla ayrılan çok sayıda tam veri seti elde edilir. Araştırmacı planladığı ANOVA veya MANOVA analizini her bir veri setine ayrı ayrı uygular ve analizden elde edilen parametre tahminleri "Rubin Kuralları" kullanılarak istatistiksel bir havuzda (pooling) birleştirilir (Schafer, 1997). Böylece hem varyans analizi için gerekli gruplar arası farklılıklar korunmuş olur, hem de tahmin edilen standart hatalar gerçeğe çok daha yakın bir şekilde esnetilmiş olur.

Günümüzde, varyans analizlerinde MI algoritmasının en yaygın ve işlevsel kullanım şekli Zincirleme Denklemlerle Çoklu Atama (Multiple Imputation by Chained Equations - MICE) yaklaşımıdır (van Buuren & Groothuis-Oudshoorn, 2011). MICE'nin en büyük avantajı, sürekli (boy, ağırlık) ve kategorik (cinsiyet, deney grubu) verilerin bir arada bulunduğu karmaşık tasarım modelleri için son derece esnek bir altyapı sunmasıdır (Azur & ark., 2011). Ancak 2020 sonrası literatürün, MICE kullanımı söz konusu olduğunda varyans analizi araştırmacılarına çok sıkı bir şekilde hatırlattığı kritik bir konsept vardır: **Model Uyumu (Model Congeniality)**. İstatistiksel uyum ilkesi, asıl yapılacak olan analizde (ANOVA) kullanılacak tüm ana etkilerin (main effects) ve özellikle faktörel etkileşim terimlerinin (interaction terms), eksik veri doldurma aşamasındaki MICE modeline mutlaka dahil edilmesi gerektiğini vurgular (Bartlett & ark., 2015; Meng, 1994). Şayet araştırmacı, bir $A \times B$ faktörel varyans analizinde A ve B faktörlerinin etkileşimini test etmeyi planlıyorsa, MICE işlemine bu etkileşim terimini bir yordayıcı (prediktör) olarak eklemek zorundadır. Bu adımın atlanması durumunda, doldurulan sentetik veriler ana etkileri korumaya çalışırken, faktörler arası etkileşimi istatistiksel olarak sıfıra çekecek şekilde gizli bir yanlılık üretecektir (White & ark., 2011).

Tam Bilgi Maksimum Olabilirlik (Full Information Maximum Likelihood - FIML)

Çoklu Atama yöntemine güçlü bir teorik alternatif olarak sunulan ve pek çok modern araştırmada eşdeğer etkinlikte olduğu kanıtlanan bir diğer modern yaklaşım ise Tam Bilgi Maksimum Olabilirlik (FIML) yöntemidir. FIML, felsefi olarak eksik hücreleri tahmin edip boşlukları sentetik verilerle doldurmak yerine, doğrudan varyans analizinin matematiksel altyapısına odaklanır. Model, eksik olan hücrelere sentetik bir değer atamakla uğraşmaz; eldeki mevcut olan tüm veriyi (full information) kullanarak, gözlemlenen veri parçalarından yola çıkarak doğrudan varyans-kovaryans matrisini ve grup ortalamalarını maksimum olabilirlik ilkesiyle tahmin eder (Enders, 2001).

FIML yaklaşımı, özellikle gruplar arası tekrarlı ölçümlerin (Repeated Measures ANOVA) uygulandığı tasarımlarda veya eksikliğin ağırlıklı olarak bağımlı değişkende (outcome variable) gözlemlendiği Karma Etkili Modellerde (Mixed-Effects Models) çoklu atamadan bile daha üstün bir performans sergileyebilmektedir (Hox & ark., 2017; Keselman & ark., 2001). Üstelik günümüzde, Yapısal Eşitlik Modellemesi (SEM) altyapısı üzerine inşa edilmiş istatistiksel yazılımlar (LISREL, AMOS, Mplus veya R dilindeki *lavaan* paketi), eksik veri problemini aşmak için FIML algoritmasını kullanıcılara varsayılan seçenek olarak sunmaktadır. Benzer şekilde, hayvancılık ve ziraat araştırmaları gibi gerçek dünya problemlerinde, veri kaybının model üzerindeki bozucu etkisini FIML prensipleriyle entegre bir şekilde değerlendiren Kısmi En Küçük Kareler (PLS-SEM) modellerinin yüksek doğrulukla çalıştığı kanıtlanmıştır (Yalçın, 2024).

Makine Öğrenmesi Tabanlı İleri Eksik Veri Algoritmaları

2020 yılından itibaren, klasik doğrusal modellere dayanan atama algoritmalarının yerini yapay zeka ve Makine Öğrenmesi (Machine Learning - ML) entegreli algoritmaların hızla almaya başladığına şahit olmaktayız. Özellikle varyans analizlerinde değişkenlerin

birbirleriyle olan doğrusal olmayan (non-linear) karmaşık ilişkilerini modelleyebilme kapasitesinden dolayı *Rastgele Orman (Random Forest)* algoritmalarına dayanan MissForest yöntemi araştırmacılar arasında büyük bir popülerite kazanmıştır (Stekhoven & Bühlmann, 2012; Tang & Ishwaran, 2017).

MissForest ve benzeri karar ağacı temelli yaklaşımlar, araştırmacının etkileşim terimlerini veya doğrusal olmayan ilişki fonksiyonlarını (polinomlar vb.) manuel olarak atama modeline tanımlamasına gerek bırakmadan, verinin içindeki doğal örüntüleri kendi kendine öğrenebilmektedir. Bu esneklik, özellikle çok sayıda faktörün ve eşdeğişkenin (covariate) bulunduğu karmaşık ANCOVA ve MANOVA tasarımlarında veri yapısının aslına en uygun şekilde korunmasını sağlamaktadır. Gelişmiş makine öğrenmesi modelleri sadece eksik veri konusunda değil; tarımsal tahminlerden su kalitesi analizlerine, tıbbi verilerden hayvansal üretim verimliliğine kadar (örneğin subklinik mastit tespiti gibi konularda) sınıflandırma ve parametre tahminleme noktasında geleneksel yaklaşımların çok ötesinde performanslar sergilemektedir (Çalış & ark., 2026; Yalçın, 2025).

Ancak, klasik istatistiksel çıkarımlara (p-değeri, F-değeri) dayanan varyans analizlerinde makine öğrenmesinin henüz aşılamayan teorik bir dezavantajı bulunmaktadır. Saf (pure) makine öğrenmesi algoritmaları eksik veriyi son derece yüksek doğrulukla "nokta tahmin" olarak doldururken, bu tahmin işleminin yarattığı istatistiksel belirsizliği (standart hatayı) ANOVA tablolarına yansıtamaz. Bu kısıtı aşmak üzere geliştirilen en güncel literatür pratiği ise *MICE ile Makine Öğrenmesinin Hibritleşmesidir*. Günümüzde araştırmacılar, MICE algoritmasının her bir iterasyonunda basit doğrusal regresyon yerine Random Forest ağaçlarını (miceRanger veya mice.impute.rf) kullanmaktadırlar. Bu sayede, modelleme esnekliği makine öğrenmesinden elde edilirken, istatistiksel geçerlilik ve doğru standart hata tahmini Rubin Kuralları

ile sağlanmakta ve eksik veri analizi modern bilimsel çağın ruhuna uygun bir şekilde tamamlanmaktadır.

Sonuç ve Gelecek Perspektifleri

Varyans analizi (ANOVA, ANCOVA, MANOVA) ekseninde kurgulanan deneysel ve gözlemsel araştırmalarda eksik veriler, kaçınılması neredeyse imkansız ancak yönetilmesi bilimsel bir zorunluluk olan yapısal bir problemdir. Son yirmi yıllık istatistiksel literatür ve yazılım teknolojilerindeki gelişmeler, eksik veri analizinin araştırma sürecinin marjinal bir basamağı olmaktan çıkıp metodolojinin bizzat merkezine yerleştiğini açıkça göstermektedir (Dong & Peng, 2013). 2020 sonrası yayın standartlarında (örneğin APA 7. Sürüm), araştırmacıların verilerini analiz etmeden önce kayıp mekanizmasını iyi teşhis etmesi ve sadece liste bazında silme veya ortalama atama gibi ilkel teknikleri kullanmayı bırakması kesin bir dille tavsiye edilmektedir (Schlomer & ark., 2010). Bu geleneksel yaklaşımlar, varyans analizinde çok ihtiyaç duyulan grup içi varyansı bozmakta, ilişkileri zedelemekte ve nihayetinde Tip I ile Tip II hata oranlarını bilimsel geçerliliği yok edecek düzeyde artırmaktadır.

Bunun yerine, araştırmacıların veri yapısına bağlı olarak, MICE gibi esnek stokastik algoritmaları veya Tam Bilgi Maksimum Olabilirlik (FIML) gibi güçlü matris tahmin yöntemlerini benimsemesi gerekmektedir. Özellikle karmaşık etkileşimlerin olduğu varyans tasarımlarında, araştırmacıların model uyumu (congeniality) kuralına dikkat etmesi hayati bir detaydır (Rubin, 1996). Çoklu Atama yönteminin, Random Forest (Rastgele Orman) gibi güçlü makine öğrenmesi algoritmalarıyla melezlenerek kullanılması, hem doğrusal olmayan (non-linear) ilişkilerin keşfedilmesini sağlamakta hem de istatistiksel çıkarsamaların (p-değerlerinin) güvenilirliğini korumaktadır. Özetle, verilerin analize dahil edilmeden önce aykırı değerlere ve yapısal anormalliklere karşı

doğru algoritmalarla normalleştirilmesi ve ardından modern imputasyon yöntemleriyle eksikliklerin giderilmesi, sağlam ve yansız bilimsel sonuçlar elde etmenin en güvenilir yoludur. Eksik verilerle başa çıkabilmek, analizlerin sadece istatistiksel geçerliliğini korumakla kalmaz; aynı zamanda araştırmmanın arkasındaki bilimsel etiğin ve veri dürüstlüğünün de en önemli teminatı olur.

Kaynakça

- Allison, P. D. (2001). *Missing data*. CA: SAGE Publications.
- American Psychological Association. (2020). *Publication manual of the American Psychological Association* (7th ed.). Washington, DC: American Psychological Association.
- Azur, M. J., Stuart, E. A., Frangakis, C., & Leaf, P. J. (2011). Multiple imputation by chained equations: what is it and how does it work?. *International Journal of Methods in Psychiatric Research*, 20(1), 40-49.
- Baraldi, A. N., & Enders, C. K. (2010). An introduction to modern missing data analyses. *Journal of School Psychology*, 48(1), 5-37.
- Bartlett, J. W., Seaman, S. R., White, I. R., & Carpenter, J. R. (2015). Multiple imputation of covariates by fully conditional specification: accommodating the substantive model. *Statistical Methods in Medical Research*, 24(4), 462-487.
- Collins, L. M., Schafer, J. L., & Kam, C. M. (2001). A comparison of inclusive and restrictive strategies in modern missing data procedures. *Psychological Methods*, 6(4), 330-351.
- Çalış, B., Bayhan, İ., Yalçın, H., Öztürk, İ., & Yeşilnacar, M. İ. (2026). Comparative Performance Analysis of Machine

- Learning Models for Predicting the Weighted Arithmetic Water Quality Index. *Water*, 18(6), 696.
- Dong, Y., & Peng, C. Y. J. (2013). Principled missing data methods for researchers. *SpringerPlus*, 2(1), 1-17.
- Enders, C. K. (2001). The performance of the full information maximum likelihood estimator in multiple regression models with missing data. *Educational and Psychological Measurement*, 61(5), 713-740.
- Enders, C. K. (2022). *Applied missing data analysis* (2nd ed.). NY: Guilford Publications.
- Field, A. (2013). *Discovering statistics using IBM SPSS statistics*. CA: Sage.
- Graham, J. W. (2009). Missing data analysis: Making it work in the real world. *Annual Review of Psychology*, 60, 549-576.
- Hox, J. J., Moerbeek, M., & Van de Schoot, R. (2017). *Multilevel analysis: Techniques and applications*. NY: Routledge.
- Keselman, H. J., Algina, J., & Kowalchuk, R. K. (2001). The analysis of repeated measures designs: a review. *British Journal of Mathematical and Statistical Psychology*, 54(1), 1-20.
- Little, R. J. (1988). A test of missing completely at random for multivariate data with missing values. *Journal of the American Statistical Association*, 83(404), 1198-1202.
- Little, R. J., & Rubin, D. B. (2019). *Statistical analysis with missing data* (3rd ed.). NJ: John Wiley & Sons.

- Maxwell, S. E., & Delaney, H. D. (2004). *Designing experiments and analyzing data: A model comparison perspective*. NJ: Lawrence Erlbaum Associates.
- Meng, X. L. (1994). Multiple-imputation inferences with uncongenial sources of input. *Statistical Science*, 9(4), 538-558.
- Rubin, D. B. (1976). Inference and missing data. *Biometrika*, 63(3), 581-592.
- Rubin, D. B. (1987). *Multiple imputation for nonresponse in surveys*. NJ: John Wiley & Sons.
- Rubin, D. B. (1996). Multiple imputation after 18+ years. *Journal of the American Statistical Association*, 91(434), 473-489.
- Schafer, J. L. (1997). *Analysis of incomplete multivariate data*. FL: CRC Press.
- Schlomer, G. L., Bauman, S., & Card, N. A. (2010). Best practices for missing data management in counseling psychology. *Journal of Counseling Psychology*, 57(1), 1-10.
- Stekhoven, D. J., & Bühlmann, P. (2012). MissForest-non-parametric missing value imputation for mixed-type data. *Bioinformatics*, 28(1), 112-118.
- Tabachnick, B. G., & Fidell, L. S. (2013). *Using multivariate statistics* (6th ed.). MA: Pearson.
- Tang, F., & Ishwaran, H. (2017). Random forest missing data algorithms. *Statistical Analysis and Data Mining*, 10(6), 363-377.
- van Buuren, S. (2018). *Flexible imputation of missing data*. FL: CRC Press.

- van Buuren, S., & Groothuis-Oudshoorn, K. (2011). mice: Multivariate imputation by chained equations in R. *Journal of Statistical Software*, 45(3), 1-67.
- White, I. R., Royston, P., & Wood, A. M. (2011). Multiple imputation using chained equations: Issues and guidance for practice. *Statistics in Medicine*, 30(4), 377-399.
- Yalçın, H. (2024). Kısmi En Küçük Kareler Yapısal Eşitlik Modellemesi (PLS-SEM). *İleri İstatistik Uygulamaları* içinde (s. 411-432). Ankara: Nobel Akademik Yayıncılık.
- Yalçın, H. (2025). Interpretable Machine Learning Models for Early Detection of Subclinical Mastitis using Routine Milk Composition Data. *ISPEC Journal of Agricultural Sciences*, 9(3), 830-843.
- Yalçın, H., Doğan, Z., Şen, S., Çetin, M., Göçmen, M., & Koçyiğit, A. (2021). The assessment of poultry welfare using partial least squares-path modelling (PLS-SEM): a modeling the effects of physical activity and stress on growth. *Harran Tarım ve Gıda Bilimleri Dergisi*, 25(1), 109-119.
- Yalçın, H., & Öztürk, İ. (2026). Aykırı Değerlere Karşı Normalleştirme Yöntemlerinin Sağlamlılığı ve Makine Öğrenmesi Performansı Üzerindeki Etkileri: Sistematik Bir Simülasyon Çalışması. *Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 9(2), 1129-1140.

