

3. BÖLÜM

HAYVANSAL ÜRETİM VE HAYVANSAL GIDA SANAYİNDE YAPAY ZEKÂ: UYGULAMALAR, SINIRLILIKLAR VE GELECEK PERSPEKTİFİ

Okan ATAY¹

Ali Kemali ÖZUĞUR²

Özdal GÖKDAL³

H. Ayla SARI⁴

Vadullah EREN⁵

1. Giriş

Küresel nüfus artışı, iklim değişikliği ve doğal kaynakların sınırlılığı, tarımsal üretim sistemleri üzerinde giderek artan bir baskı oluşturmaktadır. Dünya nüfusunun 2050 yılına kadar yaklaşık 9.7 milyara ulaşacağı ve küresel gıda talebinin 2019–2050 döneminde %50–60 oranında artacağı öngörülmektedir (Van Dijk ve ark., 2021; FAO, 2022). Özellikle besin değeri yüksek hayvansal ürünlere olan talebin hızla artması, mevcut üretim sistemlerinin sürdürülebilirliğini sorgulamakta ve kaynak kullanım etkinliği, çevresel sürdürülebilirlik, birim hayvan başına elde edilen verimin birlikte iyileştirilmesini zorunlu kılmaktadır.

Dijital teknolojilerdeki gelişmelerle birlikte, yapay zekâ (YZ), büyük veri analitiği, sensör teknolojileri ve nesnelerin interneti (IoT) temeline dayanan Hassas Hayvancılık Uygulamaları (Precision Livestock Farming, PLF) giderek yaygınlaşmaktadır. PLF sistemleri yalnızca veri toplama ve izleme araçları olmayıp, karar destek mekanizmalarını otomatikleştiren ve üretim

¹ Prof. Dr., Aydın Adnan Menderes Üniversitesi Çine MYO, 09500, Çine-Aydın /Türkiye, ORCID: 0000-0002-3783-4055

² Öğr. Gör., ORCID: 0000-0002-5064-3472

³ Prof. Dr., ORCID: 0000-0002-0130-698X

⁴ Dr. Öğr. Üyesi ORCID: 0000-0003-4282-3294

⁵ Doç. Dr., ORCID: 0000-0002-5296-7120

süreçlerinin gerçek zamanlı yönetilmesine olanak sağlayan entegre yapılar olarak tanımlanmaktadır (Wolfert ve ark., 2017; Liakos ve ark., 2018).

YZ'de kullanılan makine öğrenmesi ve derin öğrenme algoritmaları; görüntü, sensör, biyosinyal ve çevresel veriler gibi heterojen veri kaynaklarından anlamlı bilgi edinerek hayvan davranışlarının izlenmesi, hastalıkların erken teşhisi ve çeşitli verim özelliklerinin değerlendirilmesinde yüksek doğruluk sağlamaktadır (Liakos ve ark., 2018; García ve ark., 2020; Mahmud ve ark., 2021). Bununla birlikte, mevcut araştırmaların büyük bölümü kontrollü deney koşullarında yürütülmüş olup, geliştirilen sistemlerin farklı üretim koşullarına genellenebilirliği ve yetiştirici düzeyindeki uygulanabilirliğine ilişkin sorunlar bulunmaktadır.

YZ teknolojileri, hayvansal üretim aşamasının yanı sıra hayvansal gıdaların işlenmesi, kalite kontrolü ve tedarik zinciri yönetiminde de giderek daha yaygın biçimde kullanılmaktadır. Görüntü işleme ve makine öğrenmesi temelli uygulamalar; kalite sınıflandırması, mikrobiyolojik değerlendirme, anomali tespiti, raf ömrü tahmini ve risk analizi gibi alanlarda önemli uygulama olanakları sunmakta ve gıda güvenliğine yönelik kestirimci yaklaşımların geliştirilmesine katkı sağlamaktadır (Kang ve ark., 2022; Liakos ve ark., 2025). Bununla birlikte, mevcut literatürün büyük bölümü teknik performans ve doğruluk oranlarına odaklanmakta; ekonomik analizler, saha uygulanabilirliği, veri yönetimi sorunları ve etik boyutlar ise sınırlı düzeyde ele alınmaktadır.

Bu derleme, hayvansal üretim ve hayvansal gıda sanayinde kullanılan YZ uygulamalarını; verim özellikleri, hayvan refahı, çevresel sürdürülebilirlik ve gıda kalitesi üzerindeki etkileri açısından değerlendirmeyi amaçlamaktadır. Çalışma, literatürü özetlemenin ötesinde, YZ uygulamalarının sınırlılıklarını, uygulanabilirlik düzeyini ve gelecekteki araştırma gereksinimlerini eleştirel bir bakış açısıyla incelemekte; teknik performans odaklı yaklaşımların yanı sıra veri kalitesi, saha uygulanabilirliği ve ekonomik sürdürülebilirlik boyutlarını da kapsayan bütüncül bir değerlendirme sunmaktadır.

2. YZ Teknolojileri ve Hassas Hayvancılık Yaklaşımları

YZ, veri üzerinden öğrenerek karar verme, tahmin üretme ve karmaşık sistemleri modelleme yeteneğine sahip bilgisayar tabanlı yöntemler ve sistemler bütünüdür (Janiesch ve ark., 2021). YZ; makine öğrenmesi (ML),

derin öğrenme (DL), yapay sinir ağları, bilgisayarlı görme ve doğal dil işleme gibi birçok alt alanı kapsamaktadır.

Hayvansal üretim ve gıda sanayinde kullanılan YZ uygulamaları, büyük ve heterojen veri setlerinin analizine dayanmakta; sensör verileri, görüntü kayıtları, çevresel parametreler ve üretim verilerinin birlikte değerlendirilmesini gerektirmektedir. Bu nedenle YZ sistemleri yalnızca algoritmalarından ibaret olmayıp, veri toplama, veri işleme ve karar destek mekanizmalarını bir araya getiren entegre yapılar olarak ele alınmalıdır (Wolfert ve ark., 2017; Kamilaris ve Prenafeta-Boldú, 2018). Sensör tabanlı veri toplama sistemleri ile entegre edilen YZ modelleri ise hayvanların fizyolojik ve davranışsal değişimlerini sürekli izleyerek erken uyarı mekanizmalarının geliştirilmesine olanak tanımaktadır (García ve ark., 2020; Mahmud ve ark., 2021). Bu sistemler, nesnelerin interneti (IoT) altyapılarıyla birlikte çalışarak farklı veri kaynaklarının gerçek zamanlı biçimde entegre edilmesini ve üretim süreçlerinin sürekli olarak izlenmesini mümkün kılmaktadır. Bu bütüncül yapı, hassas hayvancılık uygulamalarının temelini oluşturmakta ve hayvan bazında sürekli veri izleme sayesinde üretim süreçlerinin daha hassas biçimde yönetilmesine olanak sağlamaktadır.

Makine öğrenmesi, veri üzerinden anlamlı ilişkileri öğrenerek tahmin ve sınıflandırma yapabilen algoritmaları kapsarken, derin öğrenme ise çok katmanlı yapılar sayesinde karmaşık veri ilişkilerini modelleyebilen daha gelişmiş yöntemler sunmaktadır (LeCun ve ark., 2015; Janiesch ve ark., 2021). Bu yaklaşımlar, özellikle görüntü ve zaman serisi verilerinin yoğun olduğu hayvancılık sistemlerinde davranış analizi, hastalık tespiti, kızgınlık belirleme ve çeşitli verim özelliklerinin değerlendirilmesi gibi uygulamalarda yaygın olarak kullanılmaktadır (García ve ark., 2020).

Bilgisayarlı görme teknikleri; görüntü ve video verilerinden anlamlı bilgi elde edilmesini sağlayarak hayvan davranışlarının izlenmesi, bireysel tanımlama ve sağlık göstergelerinin değerlendirilmesinde etkin bir araç olarak öne çıkmaktadır (Kamilaris ve Prenafeta-Boldú, 2018). Sensör tabanlı veri toplama sistemleri ile entegre edilen YZ modelleri ise hayvanların fizyolojik ve davranışsal değişimlerini sürekli izleyerek erken uyarı mekanizmalarının geliştirilmesine olanak tanımaktadır (García ve ark., 2020; Mahmud ve ark., 2021). Robotik sistemler, YZ ile entegre çalışarak yemleme, sağım ve çevre yönetimi gibi süreçlerin otomatikleştirilmesini sağlamakta, iş gücü ihtiyacını

azaltmakta ve üretim süreçlerinin daha hassas biçimde yönetilmesine katkı sunmaktadır (Bechar ve Vigneault, 2016; Duckett ve ark., 2018). Ayrıca YZ tabanlı karar destek sistemleri, büyük veri kaynaklarının analiz edilmesi ve üretim süreçlerine ilişkin karar mekanizmalarının geliştirilmesinde giderek daha yaygın biçimde kullanılmaktadır (Wolfert ve ark., 2017; García ve ark., 2020). Ancak bu teknolojilerin etkinliği; veri kalitesi, sensör doğruluğu, model genellenabilirliği ve yetiştiricilerin teknolojiye adaptasyonu gibi faktörlere doğrudan bağlı olup, mevcut literatürde bu konuların çoğu zaman sınırlı düzeyde ele alındığı görülmektedir (Wolfert ve ark., 2017; García ve ark., 2020; Morrone ve ark., 2022). Bu nedenle YZ teknolojilerinin, hayvansal üretim ve gıda sanayinde yalnızca veri analizi sağlayan araçlar olarak değil, aynı zamanda üretim süreçlerini iyileştiren ve karar mekanizmalarını dönüştüren bütüncül sistemler olarak değerlendirilmesi gerekmektedir.

3. Hayvansal Üretimde YZ Uygulamaları

3.1. YZ Tabanlı Sürü İzleme ve Davranış Analizi

Son yıllarda PLF uygulamalarının gelişmesiyle birlikte YZ, sürü yönetimi ve hayvan davranışlarının izlenmesinde temel teknolojilerden biri haline gelmiştir. Sensör teknolojileri, görüntü işleme sistemleri ve makine öğrenmesi algoritmalarının entegrasyonu sayesinde hayvanlara ait davranışsal ve fizyolojik veriler sürekli ve bireysel düzeyde izlenebilmekte; bu verilerin analizi ile sürü yönetiminde daha hızlı ve daha doğru kararlar alınabilmektedir (Neethirajan, 2020). Bu dönüşüm, geleneksel gözlem ve deneyime dayalı sürü yönetimi anlayışından, veri temelli ve bireysel hayvan izlemeye dayanan yönetim sistemlerine geçişi ifade etmektedir.

Radyo frekansı ile tanımlama (RFID) tabanlı kimliklendirme sistemleri, ivmeölçerler, pedometreler, jiroskoplar, retiküler boluslar, mikrofonlar, Küresel Uydu Navigasyon Sistemi (GNSS) alıcıları, sıcaklık sensörleri, kızılötesi termografi sistemleri, görüntü analizleri, 2D ve 3D kamera sistemleri ile otomatik tartım platformları aracılığıyla; geviş getirme, hareketlilik, yatma–ayakta kalma süreleri, canlı ağırlık değişimleri, ses aktiviteleri, dışkılama davranışı ile yem ve su tüketimi gibi çok sayıda parametre sürekli ve bireysel düzeyde izlenebilmektedir. Bu sistemler sayesinde hayvanların fizyolojik ve davranışsal değişimleri erken dönemde belirlenebilmekte ve olası sağlık sorunlarına zamanında müdahale edilebilmektedir (Rutten ve ark., 2013; Neethirajan, 2020).


Literatürde, derin öğrenme (DL) tabanlı yaklaşımların hayvan tanımlama ve davranış sınıflandırma çalışmalarında yüksek doğruluk oranlarına ulaştığı bildirilmektedir (García ve ark., 2020; Mahmud ve ark., 2021). Örneğin, sığırların burun izlerinin bireye özgü biyometrik özellikler taşıması sayesinde, görüntü analizi yöntemleri kullanılarak hayvanların %98'in üzerinde doğruluk oranlarıyla tanımlanabildiği rapor edilmiştir (Kumar ve ark., 2018). Benzer şekilde, görüntü tabanlı derin öğrenme sistemlerinin süt sığırlarında bireysel hayvan tanımlamada %90'ın üzerinde doğruluk sağlayabildiği bildirilmektedir (Andrew ve ark., 2021).

Hayvan davranışlarının sınıflandırılmasına yönelik çalışmalarda, YZ tabanlı sistemlerin yüksek doğruluk oranlarına ulaşabildiği bildirilmektedir. Sığırlarda genel davranışların belirlenmesinde yaklaşık %84 doğruluk elde edilirken, yatma ve ayakta durma gibi daha belirgin ve statik davranışların sınıflandırılmasında doğruluk oranlarının %99'a kadar ulaşabildiği rapor edilmiştir (Nasirahmadi ve ark., 2017; Achour ve ark., 2020). Koyunlarda davranış sınıflandırma doğruluğunun %94–97 aralığında değiştiği bildirilmektedir (Borchers ve ark., 2017). Benzer şekilde, sığırlarda kızgınlık tespiti ve çiftleşme davranışlarının belirlenmesinde YZ uygulamalarının %80'in üzerinde başarı sağladığı, özellikle kızgınlıkta atlama davranışının tespitinde doğruluk oranlarının %90'ın üzerine çıktığı belirtilmektedir (Rutten ve ark., 2013; Benaissa ve ark., 2019). Yem tüketimi ve yemleme davranışlarının izlenmesine yönelik çalışmalarda ise görüntü işleme ve sensör tabanlı sistemlerin davranışsal değişimleri belirlemede etkili sonuçlar verdiği bildirilmektedir (Nasirahmadi ve ark., 2017). Kanatlı hayvanlarda davranış analizi çalışmalarında doğruluk oranlarının %80 ile %98.5 arasında değiştiği rapor edilirken (Berckmans, 2017; Li ve ark., 2020), geniş alanlara yayılan sığırların tespitine yönelik çalışmalarda insansız hava aracı görüntülerinin Mask R-CNN algoritması ile analiz edilmesi sonucunda yaklaşık %94 doğruluk elde edildiği bildirilmektedir (Xu ve ark., 2020).

Benzer şekilde, görüntü işleme ve yapay zekâ tabanlı sistemlerin süt sığırlarında bireysel hayvan takibi ve erken topallık tespitinde önemli potansiyel taşıdığı bildirilmektedir. Özellikle anahtar nokta (keypoint) temelli hareket analizleri sayesinde postür ve yürüyüş değişimlerinin klinik belirtiler ortaya çıkmadan önce belirlenebildiği ifade edilmektedir. Ayrıca sistemin hayvana sensör takılmasını gerektirmemesi, stresin azaltılması ve sürekli

izleme açısından önemli avantajlar sunmaktadır (Bereczki-Tisza ve Mikó, 2026).

Şekil 1’de bir süt sığırcılığı işletmesinde süt ineklerinin kamera sistemleri ve YZ entegrasyonu ile benzersiz tanımlayıcılar ile tanımlanması, bireysel davranışlarının izlenmesi ve yorumlanmasına ilişkin yürütülen bir çalışmadan görüntü yer almaktadır.



Şekil 1. Kamera izleme sistemleri ve yapay zekâ entegrasyonu ile süt ineklerinin bireysel tanınması ve davranışlarının izlenmesi (Akıllı Çiftçinin Gözü Projesi (Macaristan), Computer Trends, 2024’ten alınmıştır).

3.2. Hastalıkların Erken Tespiti

Hayvancılıkta hastalıkların erken tespiti, üretim kayıplarının azaltılması, hayvan refahının korunması ve antibiyotik kullanımının sınırlandırılması açısından kritik öneme sahiptir. Erken teşhis sayesinde hastalıkların sürü içindeki yayılımı sınırlandırılabilenmekte, bireysel hayvan performansındaki düşüşler en aza indirilebilmekte ve sürü düzeyindeki verim kayıpları azaltılabilmektedir. Bu bağlamda, YZ ve sensör tabanlı sistemler, hastalıkların klinik belirtiler ortaya çıkmadan önce belirlenmesine olanak sağlayan önemli teknolojiler olarak öne çıkmaktadır.

Sığırlarda mastitis tespitine yönelik çalışmalarda, yapay sinir ağları ve makine öğrenmesi temelli modellerin hastalıklı hayvanların belirlenmesinde yüksek başarı sağlayabildiği bildirilmektedir. Otomatik sağım sistemlerinden

elde edilen veriler kullanılarak geliştirilen modellerde ise yaklaşık %80 düzeyinde doğruluk oranlarına ulaşılabildiği ifade edilmektedir (Kamphuis ve ark., 2010; Haile-Mariam ve Pryce, 2015; Neethirajan, 2020).

Topallık tespitine yönelik çalışmalarda, hareket sensörleri ve görüntü işleme teknikleri kullanılarak %90'ın üzerinde doğruluk oranlarına ulaşılabilmektedir. Bununla birlikte, hafif topallık vakalarının tespitinde model performansının daha düşük seviyelerde kaldığı ve erken dönem vakaların belirlenmesinin daha zor olduğu ifade edilmektedir (Viazzı ve ark., 2013; Schlageter-Tello ve ark., 2014; Kang ve ark., 2022). Küçükbaş hayvanlarda ağrı tespitine yönelik olarak yüz ifadelerine dayalı geliştirilen modeller %90'ın üzerinde doğruluk oranlarıyla çalışabilmektedir (McLennan ve Mahmoud, 2019). Hayvan sağlığının izlenmesine yönelik sensör ve yapay zekâ temelli çalışmalarda davranışsal ve fizyolojik anormalliklerin belirlenmesinde başarı oranları ise %70–90 aralığında değişmektedir (Jukan ve ark., 2017; Neethirajan, 2020).

Kanatlı hayvanlarda hastalık ve stres durumlarının tespitine yönelik YZ uygulamalarında doğruluk oranının %90'ın üzerine çıkabildiği bildirilmektedir (Oliveira ve ark., 2021; Machuve ve ark., 2022). Benzer şekilde, arı kolonisi sağlığının izlenmesine yönelik ses verilerine dayalı makine öğrenmesi modellerinin de yaklaşık %95 civarında doğruluk oranlarıyla çalışabildiği rapor edilmektedir (Zgank, 2021).

3.3. Verim Tahmini, Rasyon ve Besleme Stratejilerinin İyileştirilmesi

Hayvancılıkta verim tahmini ve ekonomik rasyon hazırlama stratejilerinin geliştirilmesi, üretim maliyetlerinin azaltılması ve sürdürülebilir üretim hedeflerinin gerçekleştirilmesi açısından kritik öneme sahiptir. Bu kapsamda YZ tabanlı modeller; süt, et, yumurta ve bal verimi gibi üretim parametrelerinin tahmin edilmesinde yaygın olarak kullanılmaktadır. YZ uygulamaları özellikle süt sığırlarında günlük süt verimi ve süt kompozisyonunun tahmininde kullanılmakta ve düşük hata payları ile güçlü tahmin performansı sağlayabilmektedir (Liakos ve ark., 2018; Neethirajan, 2020; Slob ve ark., 2021). Koyunlarda yapılan çalışmalarda ise meme morfolojisi ile süt verimi arasındaki ilişkilerin YZ ile modellenmesi sonucunda güvenilir tahminler yapılabildiği bildirilmektedir (Angeles-Hernandez ve ark., 2022). YZ teknolojisinin, yüksek ve düşük verimli hayvanların belirlenmesinde etkin şekilde kullanılabildiği ve bazı

çalışmalarda gelecekteki laktasyon verim düzeylerinin yaklaşık %70–73 doğrulukla sınıflandırılabilirdiği bildirilmektedir (Bovo ve ark., 2025).

Tavukçulukta yumurta üretimi ve üretim problemlerinin tahminine yönelik YZ modellerinde bazı çalışmalarda doğruluk oranlarının %98'e kadar ulaşabildiği bildirilmektedir (Ramírez-Morales ve ark., 2016).

Yemleme stratejilerinin iyileştirilmesine yönelik olarak, YZ tabanlı tahmin modellerinin yem tüketiminin öngörülmesinde etkili olduğu ve bazı çalışmalarda yem tüketiminin düşük hata paylarıyla tahmin edilebildiği bildirilmektedir. Örneğin, derin öğrenme tabanlı görüntü işleme modelleriyle bireysel yem tüketiminin yaklaşık 0,14 kg/öğün hata payı ile tahmin edilebildiği rapor edilmiştir (Saar ve ark., 2022). Ayrıca YZ ile geliştirilen besleme modellerinde yem tüketiminin tahmininde orta-yüksek düzeyde tahmin performansı elde edildiği ve bazı çalışmalarda korelasyon katsayılarının 0.52–0.65 aralığına ulaşabildiği bildirilmektedir (Salleh ve ark., 2023). YZ destekli otomatik yemleme sistemleri, hassas hayvancılık uygulamalarının önemli bileşenlerinden biri olarak değerlendirilmektedir. Bu sistemler sayesinde yemleme süreçleri insan kaynaklı gecikme, düzensizlik ve yönetim hatalarından büyük ölçüde bağımsız hale getirilebilmektedir. Özellikle hayvanların standart ve düzenli zaman aralıklarıyla yemlenebilmesi; yem tüketim davranışı, rumen stabilitesi ve sürü performansı açısından önemli avantajlar sağlamaktadır. Sensör teknolojileri ve gerçek zamanlı veri analizine dayalı hassas yemleme yaklaşımları, hayvanların bireysel besin madde gereksinimlerinin belirlenmesine ve buna uygun rasyonların oluşturulmasına olanak sağlamaktadır (Zuidhof, 2020). Ayrıca YZ algoritmaları; çevresel sıcaklık, nem ve davranış verilerini analiz ederek sıcaklık stresine bağlı yemleme zamanı değişikliklerinin dinamik biçimde yönetilmesine katkı sağlayabilmektedir. Bunun yanında otomatik yemleme sistemleri; yemlik hijyeninin sürdürülebilirliği, yem kayıplarının azaltılması ve yemden yararlanma etkinliğinin artırılması açısından da önemli avantajlar sunmaktadır. YZ tabanlı karar destek sistemlerinin bireysel verim düzeylerine göre rasyon hazırlayabilmesi, hassas besleme uygulamalarının sürdürülebilir hayvansal üretimdeki önemini daha da artırmaktadır (Akintan ve ark., 2024).

3.4. Hayvansal Üretimde YZ Uygulamalarında Uygulanabilirlik ve Temel Sınırlılıklar

Hayvansal üretimde kullanılan YZ tabanlı sistemler; davranış analizi, hastalıkların erken tespiti, verim tahmini, hassas yemleme ve üretim yönetimi gibi birçok alanda önemli avantajlar sunmasına rağmen, bu teknolojilerin saha koşullarındaki uygulanabilirliği çeşitli faktörlerden doğrudan etkilenmektedir. Literatürde bildirilen yüksek doğruluk oranlarının önemli bir bölümü kontrollü deney koşullarında elde edilmiş olup, farklı çevresel koşullar ve üretim sistemleri altında model performansının değişkenlik gösterebileceği göz ardı edilmemelidir. Ayrıca birçok çalışmada model performansının yalnızca doğruluk (accuracy) ölçütü üzerinden değerlendirilmesi, özellikle dengesiz veri setlerinde yanıltıcı sonuçlara yol açabilmektedir. Bu nedenle duyarlılık (sensitivity), özgüllük (specificity), kesinlik (precision), F1-skoru ve ROC-AUC (ROC eğrisinin altında kalan alan) gibi ek performans ölçütlerinin de dikkate alınması gerekmektedir (Sokolova ve Lapalme, 2009; García ve ark., 2020).

YZ sistemlerinin etkinliği büyük ölçüde veri kalitesine ve sensör doğruluğuna bağlıdır. Sensör arızaları, veri eksikliği, ölçüm hataları ve çevresel gürültü gibi faktörler model çıktılarının güvenilirliğini doğrudan etkileyebilmektedir. Bunun yanında farklı çiftlikler, hayvan ırkları ve yetiştirme sistemleri arasındaki yüksek veri heterojenliği, geliştirilen modellerin genellenebilirliğini zorlaştırmaktadır. Özellikle sensör tabanlı sistemlerde veri kaybı ve çevresel faktörlerden kaynaklanan gürültü, model performansını olumsuz etkileyen başlıca unsurlar arasında yer almaktadır. Bu nedenle veri ön işleme, gürültü azaltma yöntemleri ve çoklu veri kaynaklarının birlikte kullanılması model doğruluğunu artırmada kritik rol oynamaktadır (Wolfert ve ark., 2017; Tullo ve ark., 2019; García ve ark., 2020; Neethirajan, 2020; Morrone ve ark., 2022).

Hastalıkların erken teşhisine yönelik YZ uygulamalarında veri etiketleme (labeling) sürecinin zorluğu ve klinik doğrulama gerekliliği önemli sınırlılıklar arasında yer almaktadır. Ayrıca farklı hastalıkların benzer davranışsal ve fizyolojik belirtiler gösterebilmesi, modellerin yanlış sınıflandırma yapmasına neden olabilmekte ve özellikle erken teşhis aşamasında tanı doğruluğunu sınırlayabilmektedir (García ve ark., 2020; Neethirajan, 2020). Bununla birlikte geliştirilen modellerin farklı işletmeler,

iklim koşulları ve yetiştirme sistemleri altında benzer performansı gösterip göstermediği konusu günümüzde yeterince açıklığa kavuşturulamamıştır. Bu durum, model genellenebilirliğinin YZ uygulamalarının saha kullanımındaki en önemli kısıtlardan biri olduğunu göstermektedir.

Verim tahmini, rasyon hazırlama ve hassas yemleme uygulamalarında da benzer sınırlılıklar söz konusudur. Elde edilen performans değerlerinin büyük ölçüde veri yapısına, çevresel koşullara ve kullanılan üretim sistemine bağlı olarak değişebildiği bildirilmektedir. Özellikle bireysel yem tüketiminin tahmin edilmesine yönelik modellerde hayvan davranışındaki bireysel farklılıklar, çevresel stres faktörleri ve veri sürekliliği model performansını doğrudan etkileyebilmektedir (Zuidhof, 2020; Akintan ve ark., 2024). Ayrıca hassas yemleme sistemlerinin yaygın kullanımı; sensör altyapısı, otomasyon sistemleri ve veri entegrasyonu gibi unsurlar nedeniyle belirli düzeyde ekonomik yatırım gerektirmektedir. Bu durum, özellikle küçük ve orta ölçekli işletmelerde teknoloji adaptasyonunu sınırlayabilmektedir (Akintan ve ark., 2024). Avrupa Birliği ve Macaristan odaklı güncel bir değerlendirmede, hassas hayvancılık ve YZ uygulamalarının süt verimi ve sürü sağlığında önemli iyileşmeler sağladığı; ancak yüksek yatırım maliyetleri ve düşük dijital yeterlilik nedeniyle kullanım oranlarının halen sınırlı olduğu bildirilmektedir (Tatai, 2026). Bu durum, YZ tabanlı sistemlerin teknik olarak başarılı sonuçlar vermesine rağmen, saha uygulanabilirliğinin ekonomik ve yapısal faktörlerden doğrudan etkilendiğini göstermektedir.

Ayrıca YZ sistemlerinin saha koşullarında etkin şekilde kullanılabilmesi; yetiştiricilerin ve teknik personelin bu teknolojilere adaptasyon düzeyi, bakım-onarım süreçlerinin yönetimi ve yeterli teknik uzman desteğinin bulunabilirliği gibi faktörlerden de etkilenmektedir (Liakos ve ark., 2018; Wolfert ve ark., 2017). Veri güvenliği ve gizliliğine ilişkin riskler, işletmelere ait verilerin dijital sistemler aracılığıyla daha geniş ağlara taşınmasıyla birlikte önem kazanmaktadır (Wolfert ve ark., 2017). Bunun yanında aşırı uyum (overfitting) problemleri, modellerin farklı sürü ve işletme koşullarında performans kaybı yaşamasına neden olabilmektedir (Shahinfar ve ark., 2020). Otomatik sistemlerin sürü sosyal yapısı, korku, stres ve irkilme gibi bilişsel ve davranışsal değişimleri tam olarak yorumlayamaması da önemli biyolojik sınırlılıklar arasında yer almaktadır (Berckmans, 2017). Ayrıca karmaşık biyolojik verilerin makine öğrenmesi algoritmalarıyla analizinde yanlış sınıflandırmalar oluşabilmekte, disiplinler arası iş birliği gereksinimi ise

uygulama süreçlerinde ek koordinasyon güçlükleri yaratabilmektedir (Morota ve ark., 2018).

Genel olarak değerlendirildiğinde, YZ ve derin öğrenme temelli sistemlerin hayvansal üretimde önemli bir potansiyel sunduğu görülmektedir. Bununla birlikte, bu sistemlerin etkin biçimde kullanılabilmesi için yalnızca teknik doğruluğun değil; veri yönetimi, sensör güvenilirliği, ekonomik uygulanabilirlik, saha koşullarına uyum ve model genellenebilirliği gibi faktörlerin de birlikte değerlendirilmesi gerekmektedir. Bu nedenle gelecekteki çalışmaların, farklı üretim koşullarını kapsayan daha geniş ve çeşitli veri setleri kullanılarak geliştirilen, uzun dönem saha performansı doğrulanmış ve ekonomik sürdürülebilirliği değerlendirilmiş modeller üzerine yoğunlaşması önem taşımaktadır.

Şekil 2’de hayvansal üretimde yapay zekâ tabanlı sistemlerin genel çalışma akışı gösterilmektedir.


4. Hayvansal Ürünlere Dayalı Gıda Sanayinde YZ Kullanımı

4.1. Kalite Kontrol ve Sınıflandırma

Hayvansal ürünlerin işlendiği gıda sanayinde kalite kontrol süreçleri; ürün güvenliği, standardizasyon ve tüketici memnuniyeti açısından kritik öneme sahiptir. Geleneksel kalite kontrol yöntemleri büyük ölçüde insan gözlemine ve laboratuvar analizlerine dayanmakta olup zaman alıcı olabilmekte ve belirli ölçüde subjektif sonuçlar verebilmektedir. Bu noktada YZ tabanlı sistemler, kalite kontrol süreçlerinin daha hızlı, standartlaştırılmış ve sürekli şekilde yürütülmesine olanak sağlamaktadır.

YZ ve görüntü işleme tabanlı sistemler, son yıllarda gıda sanayinde kalite kontrolü, kontaminasyon tespiti, ürün sınıflandırması, raf ömrü tahmini ve üretim süreçlerinin izlenmesi gibi birçok uygulamada yaygın biçimde kullanılmaya başlanmıştır. Özellikle derin öğrenme temelli yöntemlerin, geleneksel görüntü işleme tekniklerine kıyasla daha yüksek performans gösterdiği ve daha başarılı sınıflandırma sonuçları verdiği bildirilmektedir.

Ekosistem Temelli Üretim: Ziraat, Ormanlık ve Su Ürünleri
Ecosystem-Based Production: Agriculture, Forestry and Fisheries



Şekil 2. Hassas Hayvancılıkta Yapay Zekâ Tabanlı Karar Destek ve Yönetim Sistemi (Distanto ve ark., 2025'ten uyarlanmıştır ve şeklin görsel tasarımında yapay zekâ destekli araçlardan yararlanılmıştır)

Literatürde, bazı gıda kalite kontrol ve sınıflandırma uygulamalarında yüksek doğruluk oranlarına ulaşıldığı belirtilmektedir. Bu durum, YZ tabanlı sistemlerin gıda sanayinde kalite güvencesi, otomatik denetim ve karar destek mekanizmaları açısından önemli bir potansiyele sahip olduğunu göstermektedir (Kamilaris ve Prenafeta-Boldú, 2018; Bovo ve ark., 2025).

YZ tabanlı sistemler, gıda üretim ortamlarının belirli ölçüde kontrollü olması (sabit hat hızı, standart aydınlatma ve ürün homojenliği gibi) nedeniyle daha istikrarlı analiz koşulları sunabilmektedir. Özellikle üretim hattında kamera ve sensör sistemlerinin sabit konumlandırılması, veri kalitesinin daha tutarlı olmasını sağlamak ve model çıktılarının güvenilirliğini artırmaktadır.

Bu durum, hayvancılık işletmelerindeki değişken çevresel koşullara kıyasla daha öngörülebilir bir analiz ortamı oluşturmaktadır. YZ tabanlı kalite kontrol sistemleri, yalnızca hatalı ürünlerin tespiti ile sınırlı kalmayıp ürünlerin kalite derecelerine göre sınıflandırılmasını da sağlamaktadır. Bu sistemler sayesinde üretim hattında sürekli izleme yapılabilen ve kalite standartlarının korunması daha etkin şekilde sürdürülebilmektedir.

4.2. Gıda Güvenliği ve İzlenebilirlik

Hayvansal gıdalarda gıda güvenliği ve izlenebilirlik, halk sağlığının korunması ve gıda kaynaklı risklerin azaltılması açısından kritik öneme sahiptir. Geleneksel yöntemler büyük ölçüde periyodik denetimler ve geriye dönük analizlere dayanmakta olup, potansiyel risklerin erken aşamada tespit edilmesinde sınırlı kalabilmektedir. Bu bağlamda YZ tabanlı sistemler, gıda güvenliğinin yalnızca sorun ortaya çıktıktan sonra müdahale edilen bir yapıdan, risklerin önceden belirlenebildiği ve önleyici tedbirlerin alınabildiği daha kestirimci bir yaklaşıma dönüşmesine katkı sağlayan önemli teknolojiler olarak öne çıkmaktadır.

YZ uygulamaları, özellikle mikroorganizma tespiti, kontaminasyon analizi ve kalite bozulmalarının belirlenmesinde yaygın olarak kullanılmaktadır. Gıda güvenliği alanında geliştirilen yapay zekâ destekli biyosensör ve görüntüleme sistemlerinin, *Escherichia coli*, *Salmonella* ve *Listeria monocytogenes* gibi önemli gıda kaynaklı patojenlerin hızlı ve doğru şekilde tespit edilmesinde etkili sonuçlar ortaya koyduğu bildirilmektedir. Literatürde bazı YZ tabanlı sınıflandırma modellerinde doğruluk oranlarının %87–96 aralığında değişebildiği, belirli veri setlerinde ise %93,75–100 düzeyine ulaşabildiği ifade edilmektedir. Özellikle biyosensör sistemleri ile makine

öğrenmesi algoritmalarının birlikte kullanılması, gerçek zamanlı izleme ve erken risk tespiti açısından önemli avantajlar sağlamaktadır (Law ve ark., 2015; Zhao ve ark., 2014; Gao ve ark., 2024; Banicod ve ark., 2025).

Süt ve süt ürünlerinde ise YZ uygulamalarının patojen tespiti ve kalite bozulmalarının belirlenmesinde oldukça yüksek performans gösterebildiği bildirilmektedir. Görüntü işleme, biyosensör ve sensör verilerine dayalı analiz sistemlerinde bazı çalışmalarda sınıflandırma doğruluğunun %90'ın üzerine, belirli uygulamalarda ise %98'e kadar ulaşabildiği ifade edilmektedir. Ayrıca bu sistemler, bozulma ve kontaminasyon risklerinin üretim süreci boyunca erken aşamada belirlenmesine olanak tanımaktadır (Jiang ve ark., 2025).

Mevcut çalışmaların önemli bir kısmı kontrollü laboratuvar ortamlarında gerçekleştirilmiş olup, özellikle standartlaştırılmış numuneler ve sabit analiz koşulları altında yüksek model performansları elde edildiği bildirilmektedir. Bununla birlikte, elde edilen bulguların gerçek üretim ve tedarik zinciri koşullarına uyarlanabilirliği giderek artmaktadır. Özellikle numune hazırlama süreçleri, çevresel faktörler, sensör hassasiyeti ve veri kalitesi gibi unsurlar model performansını etkileyebilmekle birlikte, gıda sanayinin görece kontrollü yapısı bu değişkenlerin daha etkin şekilde yönetilmesine olanak tanımaktadır fakat geliştirilen YZ modellerinin farklı üretim koşullarında doğrulanması ve gerçek saha verileriyle desteklenmesi, sistemlerin güvenilirliği ve uygulanabilirliği açısından önemli görülmektedir (Law ve ark., 2015; Wang ve Salazar, 2016; Neethirajan ve ark., 2018; Gao ve ark., 2024; Chhetri, 2024; Jiang ve ark., 2025).

YZ uygulamaları yalnızca tespit aşamasıyla sınırlı kalmayıp, aynı zamanda risk analizi ve sınıflandırma süreçlerinde de etkin şekilde kullanılmaktadır. Bu sistemler, büyük veri setlerini analiz ederek potansiyel tehlikeleri erken aşamada belirleyebilmekte ve gıda güvenliği yönetim sistemlerinin daha etkin işlemesine katkı sağlamaktadır (Jiang ve ark., 2025).

YZ teknolojileri ile blokzincir (blockchain) sistemlerinin birlikte kullanılması, gıda izlenebilirliği açısından önemli avantajlar sunmaktadır. Blokzincir tabanlı sistemler üretimden tüketime kadar olan süreçte veri bütünlüğünü koruyarak şeffaf ve güvenilir kayıtlar oluştururken (Kamilaris ve ark., 2017; Rejeb ve ark., 2022), YZ bu verileri analiz ederek kalite sapmalarını, tedarik zinciri aksaklıklarını ve olası gıda güvenliği risklerini erken aşamada saptayabilmektedir. Bu sayede sistemler yalnızca geçmiş

verilerin izlenmesine dayalı yapılardan çıkarak, riskleri önceden değerlendirebilen ve karar süreçlerini destekleyen daha işlevsel yapılar haline gelmektedir

YZ tabanlı gıda güvenliği sistemlerinde veri çeşitliliği ve standardizasyonun sağlanması, model performansının sürekliliği açısından önemli görülmektedir. Farklı üretim tesislerinden elde edilen verilerin daha uyumlu hale getirilmesi, sistemlerin değişken üretim koşullarına daha kolay adapte olmasına katkı sağlamaktadır. Bu sistemlerin kurulumu ve üretim hatlarına entegrasyonu belirli bir yatırım gerektirmekle birlikte, uzun vadede sağladığı kalite güvencesi, izlenebilirlik ve üretim verimliliği avantajları dikkate alındığında uygulanabilirliğinin giderek arttığı bildirilmektedir (Galvez ve ark., 2018; Rejeb ve ark., 2022; Jiang ve ark., 2025).

4.3. Üretim Süreçlerinin İyileştirilmesi

YZ teknolojileri, üretim hatlarında veri temelli karar mekanizmalarının geliştirilmesini sağlayarak üretim süreçlerinin daha etkin ve kontrollü şekilde yürütülmesine katkı sağlamaktadır (Kakani ve ark., 2020; Chhetri, 2024). Sensör sistemleri, görüntü işleme teknolojileri ve gerçek zamanlı veri analizleri sayesinde üretim süreçleri sürekli izlenebilmekte; sıcaklık, nem, işleme süresi ve ürün akışı gibi parametrelerde oluşabilecek sapmalar erken aşamada belirlenebilmektedir. Bu durum hem üretim verimliliğinin artırılmasına hem de kalite kayıplarının azaltılmasına katkı sağlamaktadır. YZ tabanlı sistemler, üretim sürecinde yer alan kritik kontrol noktalarından elde edilen verileri analiz ederek proses sapmalarını erken aşamada tespit edebilmekte ve kalite kayıplarını en aza indirmektedir. Süt ve süt ürünleri sektöründe YZ uygulamaları; üretim planlaması, kalite kontrolü, enerji verimliliği, izlenebilirlik ve sürdürülebilirlik açısından giderek daha önemli hale gelmektedir. Son yıllarda YZ destekli sistemler, IoT sensörleri ve blokzincir teknolojileri süt tedarik zincirinde yaygın biçimde kullanılmaktadır. Yapılan çalışmalar, YZ uygulamalarının süt kalitesinin tahmini, stok ve lojistik süreçlerinin iyileştirilmesi, hayvan sağlığının izlenmesi, erken hastalık tespiti ve gıda güvenliğinin artırılması gibi alanlarda önemli katkılar sağladığını göstermektedir (Nunez ve ark., 2024; Devi ve ark., 2025; Serrano-Torres ve ark., 2025). Ayrıca bu teknolojilerin gerçek zamanlı veri analizi sayesinde karar destek mekanizmalarını güçlendirdiği,

operasyonel maliyetleri azalttığı ve sürdürülebilir üretim uygulamalarını desteklediği bildirilmektedir.

Bunun yanında, gerçek üretim verileri kullanılarak gerçekleştirilen çalışmalar, YZ tabanlı modellerin süt işleme tesislerinde enerji ve üretim verimliliğini önemli ölçüde artırabildiğini göstermektedir. Özellikle çok katmanlı algılayıcı (MLP) yapay sinir ağı modellerinin, süt fabrikalarındaki üretim süreçlerinin yüksek doğrulukla tahmin edilmesi ve süreç verimliliğinin artırılmasında etkili olduğu bildirilmektedir. Türkiye’de gerçekleştirilen bir çalışmada, yapay zekâ destekli modeller sayesinde süt üretim verimliliğinde %20–40 arasında artış sağlandığı, modelin ise oldukça yüksek doğruluk değerleri ($R^2 = 0.99984$) gösterdiği belirtilmiştir (Taner ve Çolak, 2024).

Et endüstrisinde YZ tabanlı bilgisayarlı görü (CVS), hiperspektral görüntüleme ve makine öğrenmesi uygulamaları; kalite kontrol süreçlerinin daha hızlı, objektif ve otomatik şekilde yürütülmesine olanak sağlamaktadır. Bu sistemler sayesinde etin renk, tekstür, yağ dağılımı, pH ve mikrobiyal kalite gibi parametreleri gerçek zamanlı olarak analiz edilebilmektedir. Shi ve ark. (2021), yapay zekâ destekli modellerde et renk sınıflandırmasında %92,5, bozulmuş etlerin sınıflandırılmasında ise %81–100 doğruluk elde edildiğini bildirmiştir. Ayrıca hiperspektral görüntüleme ile toplam canlı bakteri yükü analizinde %97.14 doğruluk ve bazı tazelik analizlerinde 0.95–0.99 düzeyinde korelasyon katsayıları rapor edilmiştir. Sanchez ve ark. (2023), RGB, HSV ve CIELab* renk uzaylarını kullanarak geliştirdikleri makine öğrenmesi modelleriyle taze ve taze olmayan sığır eti örneklerini yüksek doğrulukla ayırt etmiş ve çok değişkenli renk analizinin geleneksel tek kanallı analizlerden daha başarılı olduğunu göstermiştir. Bunun yanında, yapay zekâ destekli hiperspektral görüntüleme sistemlerinin etin kimyasal kompozisyonu ve kalite parametrelerinin belirlenmesinde etkili olduğu bildirilmektedir. Barbin ve ark. (2013), yakın kızılötesi hiperspektral görüntüleme ile domuz etinin kimyasal bileşiminin yüksek doğrulukla tahmin edilebildiğini belirtirken, Alvarez-García ve ark. (2024) yapay zekâ tabanlı sistemlerin et kalitesi parametrelerinin ölçümü ve izlenebilirlik süreçlerinde etkin şekilde kullanılabildiğini bildirmiştir.

YZ teknolojilerinin üretim süreçlerindeki en önemli katkılarından biri, süreçlerin yalnızca izlenmesi değil, aynı zamanda öngörülmesi ve veri temelli karar mekanizmalarıyla yönetilebilmesidir. Bu kapsamda kestirimci analiz

uygulamaları; üretim miktarı, enerji kullanımı, ürün akışı ve verimlilikte ortaya çıkabilecek sapmaların önceden değerlendirilmesine olanak sağlamaktadır. Gerçek üretim verileriyle yürütülen bir çalışmada, MLP tabanlı yapay sinir ağı modelinin süt işleme tesisinde üretim ve enerji verimliliğini yüksek doğrulukla tahmin ettiği; modelin R^2 değerinin 0.99984, MSE değerinin ise 4.02×10^{-6} olduğu bildirilmiştir (Taner ve Çolak, 2024). Benzer şekilde, süt endüstrisinde YZ tabanlı kestirimci analizlerin üretim, kalite, lojistik ve kaynak yönetiminde karar süreçlerini desteklediği belirtilmektedir (Serrano-Torres ve ark., 2025; Pérez Núñez ve ark., 2026).

Dijital ikiz (digital twin) teknolojileri, fiziksel sistemlerin sanal ortamda gerçek zamanlı verilerle temsil edilmesini sağlayan dijital modeller olarak tanımlanmaktadır (Grieves ve Vickers, 2017). Bu teknolojiler, üretim süreçlerinin sanal ortamda modellenmesine olanak sağlayarak farklı üretim senaryolarının gerçek sisteme uygulanmadan önce değerlendirilmesini mümkün kılmaktadır. Böylece üretim hattındaki değişkenler gerçek zamanlı olarak izlenebilmekte, olası darboğazlar ve verim kayıpları önceden analiz edilebilmektedir. Tao ve ark. (2019), dijital ikiz teknolojilerinin üretim sistemlerinde gerçek zamanlı izleme, kestirimci analiz ve süreç yönetimi açısından önemli avantajlar sağladığını belirtirken, Fuller ve ark. (2020) bu yaklaşımın özellikle karmaşık üretim sistemlerinde karar destek mekanizmalarını güçlendirdiğini bildirmiştir.

YZ tabanlı üretim süreçlerinin iyileştirilmesi çalışmaları; veri kalitesi, sensör altyapısı ve sistem entegrasyonu ile doğrudan ilişkilidir. Sensörlerden elde edilen verilerin doğruluğu ve sürekliliği, model performansını ve karar destek mekanizmalarının güvenilirliğini doğrudan etkilemektedir. Bu nedenle yüksek kaliteli veri akışı ve güçlü entegrasyon altyapısı, YZ sistemlerinin etkinliği açısından kritik öneme sahiptir (Fuller ve ark., 2020; Serrano-Torres ve ark., 2025). Son yıllarda gerçek zamanlı veri analizi, IoT tabanlı izleme sistemleri ve sürekli güncellenebilen yapay zekâ modellerine yönelik çalışmaların artış gösterdiği bildirilmektedir (Pérez Núñez ve ark., 2026; Serrano-Torres ve ark., 2025). Bu gelişmelerin, YZ sistemlerinin farklı üretim ortamlarında daha etkin ve sürdürülebilir şekilde kullanılmasına katkı sağlayabileceği düşünülmektedir.

YZ uygulamalarının üretim hatlarına entegrasyonu belirli teknik altyapı ve sistem uyumluluğu gerektirse de, dijital üretim teknolojilerindeki gelişmelerle

birlikte bu süreçlerin daha entegre ve veri odaklı şekilde yürütülebildiği bildirilmektedir. Özellikle sensörler, IoT tabanlı izleme sistemleri ve gerçek zamanlı veri akışının üretim süreçlerine entegre edilmesi; sistemler arası veri paylaşımını kolaylaştırmakta ve üretim süreçlerinin daha bütüncül şekilde yönetilmesine katkı sağlamaktadır (Fuller ve ark., 2020; Serrano-Torres ve ark., 2025).

Ekonomik açıdan değerlendirildiğinde, YZ tabanlı sistemlerin kurulumu ve üretim süreçlerine entegrasyonu belirli bir başlangıç yatırımı gerektirmektedir. Bununla birlikte, dijital üretim teknolojileri ve veri temelli karar mekanizmalarının; üretim verimliliği, kalite kontrolü ve kaynak yönetimi açısından önemli avantajlar sağlayabileceği bildirilmektedir. Bu nedenle YZ tabanlı sistemlerin endüstriyel üretim süreçlerinde kullanımına yönelik ilginin ve uygulama çalışmalarının son yıllarda artış gösterdiği belirtilmektedir (Wang ve ark., 2015; Xu ve ark., 2018).

4.4. Hayvansal Ürünlere Dayalı Sanayide YZ Uygulamalarında Uygulanabilirlik ve Temel Sınırlılıklar

Hayvansal ürünlere dayalı gıda sanayinde kullanılan YZ tabanlı sistemler; kalite kontrol, ürün sınıflandırma, gıda güvenliği, izlenebilirlik ve üretim süreçlerinin yönetimi gibi birçok alanda önemli avantajlar sunmaktadır. Bununla birlikte, bu sistemlerin endüstriyel ölçekte sürdürülebilir biçimde uygulanabilmesi çeşitli teknik, operasyonel ve ekonomik sınırlılıklardan etkilenmektedir. Özellikle kontrollü laboratuvar veya pilot ölçekli çalışmalarda elde edilen yüksek performans değerlerinin gerçek üretim hatlarında aynı düzeyde sürdürülememesi, literatürde sıkça vurgulanan temel sorunlardan biri olarak değerlendirilmektedir (Kamilaris ve Prenafeta-Boldú, 2018; Wolfert ve ark., 2017).

YZ tabanlı kalite kontrol sistemlerinde veri standardizasyonu ve ürün heterojenliği önemli sınırlılıklar oluşturmaktadır. Et, süt ve süt ürünleri gibi biyolojik materyallerin doğal varyasyon göstermesi; renk, tekstür, nem, yağ oranı ve yüzey özelliklerinin ürünler arasında değişmesine neden olmakta ve geliştirilen modellerin farklı üretim partileri veya işletmeler arasında tutarlı performans göstermesini zorlaştırabilmektedir (Shi ve ark., 2021; Sanchez ve ark., 2023). Görüntü işleme ve hiperspektral görüntüleme sistemlerinde ışık değişimleri, yüzey yansımaları, çevresel gürültü ve sensör kalibrasyonundaki farklılıklar da model doğruluğunu doğrudan etkileyebilmektedir (Kakani ve

ark., 2020). Bunun yanında sensör arızaları, veri kaybı ve ölçüm hataları gibi teknik problemler, sistemlerin güvenilirliğini sınırlandıran diğer önemli faktörler arasında yer almaktadır.

Gıda güvenliği ve kontaminasyon tespitine yönelik YZ uygulamalarında veri etiketleme süreçleri ve referans analiz gereksinimleri önemli operasyonel güçlükler oluşturmaktadır. Özellikle mikrobiyolojik kontaminasyonların heterojen dağılım göstermesi ve düşük düzeylerde bulunabilmesi, erken aşamadaki bozulmaların belirlenmesini zorlaştırabilmektedir. Ayrıca Hayvansal Üretim bölümünde de vurguladığımız gibi gıda alanında da birçok çalışmada model performansının yalnızca doğruluk (accuracy) oranı üzerinden değerlendirilmesi, özellikle dengesiz veri setlerinde yanıltıcı sonuçlara neden olabilmektedir (Sokolova ve Lapalme, 2009; Gao ve ark., 2024). YZ tabanlı izlenebilirlik ve üretim yönetim sistemlerinde veri entegrasyonu ve altyapı uyumluluğu da önemli sınırlılıklar arasında yer almaktadır. Farklı üretim ekipmanları, sensör altyapıları ve yazılım sistemleri arasında veri standardizasyonunun sağlanamaması, gerçek zamanlı veri paylaşımını ve süreç yönetimini zorlaştırabilmektedir (Wolfert ve ark., 2017). Özellikle blokzincir tabanlı izlenebilirlik sistemlerinde yüksek veri hacmi, işlem maliyetleri ve ölçeklenebilirlik sorunları uygulamaların yaygın kullanımını sınırlandırabilmektedir (Rejeb ve ark., 2022). Bunun yanında veri güvenliği, veri sahipliği ve siber güvenlik konuları da endüstriyel YZ uygulamalarında giderek daha fazla önem kazanmaktadır (Barredo Arrieta ve ark., 2020).

Bir diğer önemli sınırlılık ekonomik uygulanabilirliktir. Hiperspektral görüntüleme sistemleri, yüksek çözünürlüklü kameralar, sensör altyapıları, otomasyon ekipmanları ve veri depolama çözümleri önemli düzeyde yatırım maliyeti gerektirebilmektedir. Bu durum özellikle küçük ve orta ölçekli işletmelerde teknoloji adaptasyonunu sınırlandırabilmektedir (Rotz ve ark., 2019). Ayrıca bu sistemlerin etkin biçimde kullanılabilmesi için teknik uzmanlık, personel eğitimi, düzenli bakım ve sürekli veri yönetimi gereksinimleri de önemli operasyonel yükler oluşturmaktadır.

Genel olarak değerlendirildiğinde, YZ tabanlı sistemlerin hayvansal ürünlere dayalı gıda sanayinde kalite, güvenlik, izlenebilirlik ve süreç yönetimi açısından önemli bir potansiyel sunduğu görülmektedir. Bununla birlikte, bu teknolojilerin endüstriyel ölçekte sürdürülebilir biçimde


uygulanabilmesi; veri standardizasyonu, altyapı uyumluluğu, ekonomik uygulanabilirlik, veri güvenliği, model genellenebilirliği ve saha koşullarına adaptasyon gibi faktörlerin birlikte değerlendirilmesini gerektirmektedir. Bu nedenle gelecekte geliştirilecek sistemlerin yalnızca yüksek doğruluk değil, aynı zamanda ölçeklenebilirlik, sürdürülebilirlik ve endüstriyel entegrasyon açısından da değerlendirilmesi gerekmektedir.

5. Gelecek Perspektifi

YZ teknolojilerinin, hayvansal üretim ve hayvansal ürünlere dayalı gıda sanayinde yalnızca mevcut süreçlerin iyileştirilmesinde değil, aynı zamanda üretim sistemlerinin yeniden şekillendirilmesinde de önemli bir rol üstleneceği öngörülmektedir. Akıllı üretim sistemlerinin gelişimiyle birlikte gerçek zamanlı karar destek mekanizmaları, üretim süreçlerinin daha hassas izlenmesi ve kaynak kullanımının daha verimli yönetilmesi mümkün hale gelmektedir. Bu gelişmelerin, sürdürülebilirlik ve üretim verimliliği açısından önemli katkılar sağlayabileceği bildirilmektedir (Wolfert ve ark., 2017; Liakos ve ark., 2018).

Gelecekte veri temelli ve yüksek düzeyde otomasyon içeren üretim sistemlerinin daha yaygın hale gelmesi beklenmektedir. Özellikle görüntü, ses, biyosensör ve çevresel verilerin birlikte değerlendirildiği çok modlu veri entegrasyonu (multimodal data fusion) yaklaşımlarının; hayvan sağlığı, refahı ve üretim performansının daha doğru biçimde değerlendirilmesine katkı sağlayabileceği belirtilmektedir (Neethirajan, 2020). Bu yaklaşımın, tek veri kaynağına dayalı sistemlerin sınırlılıklarını azaltarak daha bütüncül karar destek mekanizmalarının geliştirilmesini destekleyeceği düşünülmektedir. Ayrıca YZ sistemlerinin gelecekte yalnızca tahmin yapan araçlar olmaktan çıkarak yarı otonom ve otonom üretim süreçlerinde daha etkin rol üstlenmesi beklenmektedir ki bu uygulamaların ön örnekleri şu anda bile kullanılmaya başlanmıştır.

Ekosistem Temelli Üretim: Ziraat, Ormancılık ve Su Ürünleri
Ecosystem-Based Production: Agriculture, Forestry and Fisheries



Şekil 3. Tarıma Dayalı Gıda Sanayinde Yapay Zekâ Tabanlı Üretim ve Kalite Yönetim Sistemi (Kutyauripo ve ark., 2023; Javaid ve ark., 2023 temel alınarak oluşturulmuştur ve şeklin görsel tasarımında yapay zekâ destekli araçlardan yararlanılmıştır).

Tablo 1. Hayvansal üretim ve hayvansal gıda sanayinde yapay zekâ uygulamalarının başlıca kullanım alanları, uygulama amaçları ve saha uygulanabilirlikleri.

Uygulama Alanı	Kullanılan Yaklaşım	Başlıca Amaç	Saha Güvenilirliği / Uygulanabilirlik	Literatür
Hayvan davranışlarının izlenmesi	Görüntü işleme, CNN, derin öğrenme	Davranış analizi ve bireysel tanımlama	Kontrollü koşullarda yüksek, saha koşullarında değişken	Nasirahmadi ve ark. (2017); Achour ve ark. (2020); Andrew ve ark. (2021)
Sensör tabanlı sürü izleme	Sensör teknolojileri, IoT	Hareketlilik ve davranış takibi	Sensör kalitesine bağlı olarak orta-yüksek	Rutten ve ark. (2013); Neethirajan (2020)
Kızgınlık ve üreme takibi	Hareket sensörleri, ML	Kızgınlık tespiti ve üreme performans değerlendirmeleri	Ticari işletmelerde uygulanabilirliği yüksek	Rutten ve ark. (2013); Benaissa ve ark. (2019)
Hastalıkların erken tespiti	ML, yapay sinir ağları	Mastitis ve topallık tespiti	Klinik doğrulama gereksinimi nedeniyle orta	Kamphuis ve ark. (2010); Viazzi ve ark. (2013)
Verim tahmini	ANN, ML	Süt ve yumurta verimi tahmini	Veri kalitesine duyarlı	Angeles-Hernandez ve ark. (2022); Bovo ve ark. (2025)
Hassas yemleme	Derin öğrenme, karar destek sistemleri	Yem tüketimi ve rasyon yönetimi	Büyük işletmelerde uygulanabilirliği daha yüksek	Zuidhof (2020); Saar ve ark. (2022); Akintan ve ark. (2024)

Ekosistem Temelli Üretim: Ziraat, Ormancılık ve Su Ürünleri
Ecosystem-Based Production: Agriculture, Forestry and Fisheries

Uygulama Alanı	Kullanılan Yaklaşım	Başlıca Amaç	Saha Güvenilirliği / Uygulanabilirlik	Literatür
Kalite kontrol	Bilgisayarlı görü, hiperspektral görüntüleme	Ürün sınıflandırması	Kontrollü üretim ortamlarında yüksek	Kakani ve ark. (2020); Shi ve ark. (2021)
Gıda güvenliği	ML, biyosensör entegrasyonu	Patojen ve kontaminasyon tespiti	Laboratuvar ve endüstriyel sistemlerde yüksek	Law ve ark. (2015); Gao ve ark. (2024)
İzlenebilirlik sistemleri	Blockchain + YZ	Tedarik zinciri yönetimi	Veri standardizasyonuna bağımlı	Rejeb ve ark. (2022)
Dijital üretim yönetimi	Dijital ikiz, IoT, karar destek sistemleri	Süreç yönetimi	Yüksek altyapı gereksinimi nedeniyle sınırlı	Fuller ve ark. (2020); Taner ve Çolak (2024)

Açıklanabilir YZ (Explainable AI, XAI) yaklaşımlarının geliştirilmesi, özellikle hayvancılık ve gıda üretimi gibi yüksek riskli alanlarda kullanıcı güveni ve sistemlerin kabul edilebilirliği açısından önem taşımaktadır. Bu nedenle gelecekte yalnızca yüksek performans sağlayan değil, aynı zamanda karar mekanizmaları kullanıcı tarafından yorumlanabilen ve denetlenebilen sistemlerin daha fazla önem kazanacağı öngörülmektedir (Samek ve ark., 2017; Barredo Arrieta ve ark., 2020).

Gıda sanayinde dijital ikiz (digital twin), IoT ve blokzincir tabanlı sistemlerin kullanımının giderek yaygınlaşacağı bildirilmektedir. Bu teknolojiler; üretim süreçlerinin gerçek zamanlı izlenmesi, farklı üretim senaryolarının değerlendirilmesi, risk analizi ve izlenebilirlik açısından önemli avantajlar sunmaktadır (Kamilaris ve ark., 2017; Tao ve ark., 2019; Fuller ve ark., 2020). Özellikle YZ ile blokzincir entegrasyonunun, veri bütünlüğü ve gıda güvenliği yönetiminde daha önleyici ve veri odaklı yaklaşımların geliştirilmesine katkı sağlayabileceği belirtilmektedir (Jiang ve ark., 2025).

Bunun yanında YZ teknolojilerinin sürdürülebilir üretim hedefleriyle entegrasyonu giderek daha fazla önem kazanmaktadır. Karbon ayak izi analizleri, enerji ve su kullanımının azaltılması ile yem verimliliğinin artırılması gibi alanlarda YZ tabanlı modellerin çevresel sürdürülebilirliğe katkı sağlayabileceği bildirilmektedir (Monteiro ve Gökdağ, 2026). Bununla birlikte, yüksek yatırım maliyetleri, teknik altyapı gereksinimleri, veri yönetimi sorunları, veri güvenliği ve etik konuların özellikle küçük ve orta ölçekli işletmelerde YZ uygulamalarının yaygınlaşmasını sınırlandırabildiği ifade edilmektedir (Rotz ve ark., 2019; Driessen ve Heutinck, 2015; Barredo Arrieta ve ark., 2020).

Bu bağlamda gelecekteki çalışmaların yalnızca model doğruluğunu artırmaya değil; aynı zamanda düşük maliyetli, ölçeklenebilir, farklı üretim sistemlerine uyum sağlayabilen, kullanıcı dostu ve etik açıdan sürdürülebilir YZ çözümlerinin geliştirilmesine odaklanması gerekmektedir.

6. SONUÇ

YZ teknolojileri, hayvansal üretim ve hayvansal üretime dayalı gıda sanayinde verimlilik artışı, hayvan refahının izlenmesi, hastalıkların erken teşhisi, üretim süreçlerinin yönetimi ve gıda güvenliği gibi birçok alanda önemli gelişmeler sağlamıştır. Sensör teknolojileri, bilgisayarlı görüş sistemleri, biyosensörler, IoT tabanlı veri toplama altyapıları ve makine öğrenmesi modelleri sayesinde üretim süreçlerinin daha hassas, hızlı ve veri temelli şekilde yönetilmesi mümkün hale gelmiştir. Özellikle gerçek zamanlı veri analizi ve otomatik karar destek sistemleri, üretim kayıplarının azaltılması ve kalite kontrol süreçlerinin güçlendirilmesi açısından önemli avantajlar sunmaktadır.

Bununla birlikte mevcut literatürün önemli bir kısmı teknik performans ve model doğruluğu üzerine yoğunlaşmakta; model genellenebilirliği, veri standardizasyonu, saha uygulanabilirliği, ekonomik sürdürülebilirlik, veri güvenliği ve etik boyutlar çoğu zaman sınırlı düzeyde ele alınmaktadır. Ayrıca geliştirilen modellerin önemli bir kısmının kontrollü koşullarda oluşturulmuş olması, farklı üretim ortamlarına adaptasyon konusunda bazı sınırlılıklar ortaya çıkarabilmektedir. Bu nedenle gelecekte geliştirilecek sistemlerde veri kalitesi, sensör entegrasyonu, açıklanabilir yapay zekâ (XAI) yaklaşımları ve kullanıcı güveni gibi unsurların daha fazla önem kazanacağı düşünülmektedir.

Önümüzdeki yıllarda multimodal veri entegrasyonu, dijital ikiz teknolojileri, blokzincir tabanlı izlenebilirlik sistemleri ve otonom karar destek mekanizmalarının hayvansal üretim ve gıda sistemlerinde daha yaygın hale gelmesi beklenmektedir. Bu teknolojilerin entegre kullanımı; hayvan sağlığı ve refahının izlenmesi, verim özelliklerinin daha hassas yönetimi, sürdürülebilir kaynak kullanımı ve gıda güvenliğinin sağlanması açısından daha bütüncül, kestirimci ve veri temelli üretim modellerinin geliştirilmesine olanak sağlayabilir. Bununla birlikte, bu dönüşümün sürdürülebilir biçimde uygulanabilmesi için geliştirilecek sistemlerin düşük maliyetli, ölçeklenebilir, farklı üretim koşullarına uyum sağlayabilen ve kullanıcı tarafından denetlenebilir yapıda olması kritik önem taşımaktadır.

Sonuç olarak YZ teknolojileri, mevcut sınırlılıkların aşılması ve disiplinler arası iş birliklerinin güçlendirilmesi durumunda, gelecekte hayvansal üretim ve gıda sistemlerinin dijital dönüşümünde stratejik bir bileşen haline gelecektir.

KAYNAKLAR

- Van Dijk, M., Morley, T., Rau, M. L., & Saghai, Y. (2021). A meta-analysis of projected global food demand and population at risk of hunger for the period 2010–2050. *Nature Food*, 2(7), 494–501. <https://doi.org/10.1038/s43016-021-00322-9>
- FAO. (2022). *The future of food and agriculture – Drivers and triggers for transformation*. Food and Agriculture Organization of the United Nations. <https://doi.org/10.4060/cc0959en>
- Wolfert, S., Ge, L., Verdouw, C., & Bogaardt, M. J. (2017). Big data in smart farming: A review. *Agricultural Systems*, 153, 69–80. <https://doi.org/10.1016/j.agsv.2017.01.023>
- Liakos, K. G., Busato, P., Moshou, D., Pearson, S., & Bochtis, D. (2018). Machine learning in agriculture: A review. *Sensors*, 18(8), 2674. <https://doi.org/10.3390/s18082674>
- García, R., Aguilar, J., Toro, M., Pinto, A., & Rodríguez, J. (2020). A systematic literature review on the use of machine learning in precision livestock farming. *Computers and Electronics in Agriculture*, 179, 105826. <https://doi.org/10.1016/j.compag.2020.105826>
- Mahmud, M. S., Zahid, A., Das, A. K., Muzammil, M., & Khan, M. U. (2021). A systematic literature review on deep learning applications for precision cattle farming. *Computers and Electronics in Agriculture*, 187, 106313. <https://doi.org/10.1016/j.compag.2021.106313>
- Kang, Z., Zhao, Y., Chen, L., Guo, Y., Mu, Q., & Wang, S. (2022). Advances in machine learning and hyperspectral imaging in the food supply chain. *Food Engineering Reviews*, 14, 596–616. <https://doi.org/10.1007/s12393-022-09322-2>
- Liakos, K. G., Athanasiadis, V., Bozinou, E., & Lalas, S. I. (2025). Machine learning for quality control in the food industry: A review. *Foods*, 14(19), 3424. <https://doi.org/10.3390/foods14193424>
- Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine learning and deep learning. *Electronic Markets*, 31(3), 685–695. <https://doi.org/10.1007/s12525-021-00475-2>
- Kamilaris, A., & Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture*, 147, 70–90. <https://doi.org/10.1016/j.compag.2018.02.016>
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521, 436–444. <https://doi.org/10.1038/nature14539>
- Computer Trends. (2024). *SZTE mezőgazdasági kar: A teheneknek nincs magánéletük*. <https://www.computertrends.hu/technologia/szte-mezogazdasagi-kar-a-teheneknek-nincs-maganeletuk-382061.html>
- Duckett, T., Pearson, S., Blackmore, S., Grieve, B., Chen, W. H., Cielniak, G., et al. (2018). Agricultural robotics: The future of robotic agriculture. *arXiv*. <https://doi.org/10.48550/arXiv.1806.06762>
- Bechar, A., & Vigneault, C. (2016). Agricultural robots for field operations: Concepts and components. *Biosystems Engineering*, 149, 94–111. <https://doi.org/10.1016/j.biosystemseng.2016.06.014>

- Distante, D., Ali, M. M., Chessa, S., Giannetto, C., & Tolone, M. (2025). Artificial intelligence applied to precision livestock farming. *Smart Agricultural Technology*, 11, 100889. <https://doi.org/10.1016/j.atech.2025.100889>
- Morrone, S., Dimauro, C., Gambella, F., & Cappai, M. G. (2022). Industry 4.0 and Precision Livestock Farming (PLF): An up-to-date overview across animal productions. *Sensors*, 22(12), 4319. <https://doi.org/10.3390/s22124319>
- Neethirajan, S. (2020). The role of sensors, big data and machine learning in modern animal farming. *Sensing and Bio-Sensing Research*, 29, 100367. <https://doi.org/10.1016/j.sbsr.2020.100367>
- Rutten, C. J., Velthuis, A. G. J., Steeneveld, W., & Hogeveen, H. (2013). Sensors to support health management on dairy farms. *Journal of Dairy Science*, 96(4), 1928–1952. <https://doi.org/10.3168/jds.2012-6107>
- Kumar, S., Tiwari, S., & Singh, S. K. (2018). Deep learning framework for recognition of cattle using muzzle point image pattern. *Measurement*, 116, 1–17. <https://doi.org/10.1016/j.measurement.2017.10.064>
- Andrew, W., Greatwood, C., & Burghardt, T. (2021). Visual identification of individual Holstein-Friesian cattle via deep metric learning. *Computers and Electronics in Agriculture*, 185, 106133. <https://doi.org/10.1016/j.compag.2021.106133>
- Nasirahmadi, A., Edwards, S. A., & Sturm, B. (2017). Implementation of machine vision for detecting behaviour of cattle and pigs. *Livestock Science*, 202, 25–38. <https://doi.org/10.1016/j.livsci.2017.05.014>
- Achour, B., Belkadi, M., Filali, I., Laghrouche, M., & Lahdir, M. (2020). Image analysis for individual identification and feeding behaviour monitoring of dairy cows based on convolutional neural networks (CNN). *Biosystems Engineering*, 198, 31–49. <https://doi.org/10.1016/j.biosystemseng.2020.07.019>
- Borchers, M. R., Chang, Y. M., Proudfoot, K. L., Wadsworth, B. A., Stone, A. E., & Bewley, J. M. (2017). Machine-learning-based calving prediction from activity, lying, and ruminating behaviors in dairy cattle. *Journal of Dairy Science*, 100(7), 5664–5674. <https://doi.org/10.3168/jds.2016-11526>
- Benaissa, S., Tuytens, F. A. M., Plets, D., De Pessemier, T., Trogh, J., Tanghe, E., et al. (2019). On the use of on-cow accelerometers for the classification of behaviours in dairy barns. *Research in Veterinary Science*, 125, 425–433. <https://doi.org/10.1016/j.rvsc.2017.10.005>
- Berckmans, D. (2017). General introduction to precision livestock farming. *Animal Frontiers*, 7(1), 6–11. <https://doi.org/10.2527/af.2017.0102>
- Li, G., Zhao, Y., Purswell, J. L., Du, Q., Chesser, G. D., Jr., & Lowe, J. W. (2020). Analysis of feeding and drinking behaviors of group-reared broilers via image processing. *Computers and Electronics in Agriculture*, 175, 105596. <https://doi.org/10.1016/j.compag.2020.105596>
- Xu, B., Wang, W., Falzon, G., Kwan, P., Guo, L., Gao, Y., et al. (2020). Livestock classification and counting in quadcopter aerial images using Mask R-CNN. *International Journal of Remote Sensing*, 41(21), 8121–8142. <https://doi.org/10.1080/01431161.2020.1754491>

- Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing & Management*, 45(4), 427–437. <https://doi.org/10.1016/j.ipm.2009.03.002>
- Kamphuis, C., Mollenhorst, H., Heesterbeek, J. A. P., & Hogeveen, H. (2010). Detection of clinical mastitis with sensor data from automatic milking systems is improved by using decision-tree induction. *Journal of Dairy Science*, 96(3), 1620–1631. <https://doi.org/10.3168/jds.2010-3228>
- Tatai, A. (2026, May 21). *The impact of digitalization and artificial intelligence on the efficiency of livestock production sectors*. In *23rd Wellmann International Scientific Conference, Book of Abstracts*. University of Szeged Faculty of Agriculture.
- Haile-Mariam, M., & Pryce, J. E. (2015). Variances and correlations of milk production, fertility, longevity, and type traits over time in Australian dairy cattle. *Journal of Dairy Science*, 98(10), 7364–7379. <https://doi.org/10.3168/jds.2015-9537>
- Viazzi, S., Bahr, C., Schlageter-Tello, A., Van Hertem, T., Romanini, C. E. B., Halachmi, I., Lokhorst, C., & Berckmans, D. (2013). Analysis of individual classification of lameness using automatic measurement of back posture in dairy cattle. *Journal of Dairy Science*, 96(1), 257–266. <https://doi.org/10.3168/jds.2012-5806>
- Jukan, A., Masip-Bruin, X., & Amla, N. (2017). Smart computing and sensing technologies for animal welfare: A systematic review. *ACM Computing Surveys*, 50(5), 1–27. <https://doi.org/10.1145/3075930>
- Oliveira, D. A. B., Pereira, L. G. R., Bresolin, T., Ferreira, R. E. P., & Dorea, J. R. R. (2021). A review of deep learning algorithms for computer vision systems in livestock. *Livestock Science*, 253, 104700. <https://doi.org/10.1016/j.livsci.2021.104700>
- Machuve, D., Nwankwo, E., Mduma, N., & Mbelwa, J. (2022). Poultry diseases diagnostics models using deep learning. *Frontiers in Artificial Intelligence*, 5, 733345. <https://doi.org/10.3389/frai.2022.733345>
- Schlageter-Tello, A., Bokkers, E. A. M., Groot Koerkamp, P. W. G., Van Hertem, T., Viazzi, S., Romanini, C. E. B., et al. (2014). Manual and automatic locomotion scoring systems in dairy cows: A review. *Preventive Veterinary Medicine*, 116(1–2), 12–25. <https://doi.org/10.1016/j.pvetmed.2014.06.006>
- Zgank, A. (2021). IoT-based bee swarm activity acoustic classification using deep neural networks. *Sensors*, 21(6), 2033. <https://doi.org/10.3390/s21030676>
- Tullo, E., Finzi, A., & Guarino, M. (2019). Environmental impact of livestock farming and Precision Livestock Farming as a mitigation strategy. *Science of the Total Environment*, 650, 2751–2760. <https://doi.org/10.1016/j.scitotenv.2018.10.018>
- Morota, G., Ventura, R. V., Silva, F. F., Koyama, M., & Fernando, S. C. (2018). Machine learning and data mining advance predictive big data analysis in precision animal agriculture. *Journal of Animal Science*, 96(4), 1540–1550. <https://doi.org/10.1093/jas/sky014>

- Angeles-Hernandez, J. C., Pollott, G. E., Albarran-Portillo, B., Ramirez-Valverde, R., & Castillo-Maldonado, P. P. (2022). Prediction of milk yield from udder morphology in dairy sheep using artificial neural networks. *Scientific Reports*, 12, 8967. <https://doi.org/10.1038/s41598-022-12868-0>
- Kutyaauripo, I., Rushambwa, M., & Chiwazi, L. (2023). Artificial intelligence applications in the agrifood sectors. *Journal of Agriculture and Food Research*, 11, 100502. <https://doi.org/10.1016/j.jafr.2023.100502>
- Javaid, M., Haleem, A., Khan, I. H., & Suman, R. (2023). Understanding the potential applications of artificial intelligence in agriculture sector. *Advanced Agrochem*, 2(1), 15–30. <https://doi.org/10.1016/j.aac.2022.10.001>
- Bovo, M., Agrusti, M., Ozella, L., Forte, C., Torreggiani, D., & Tassinari, P. (2025). A viable data-driven method for the assessment of the productivity level of dairy cows in future lactations. *Computers and Electronics in Agriculture*, 230, 109860. <https://doi.org/10.1016/j.compag.2024.109860>
- Ramírez-Morales, I., Rivero-Cebrián, D., Fernández-Blanco, E., & Pazos-Sierra, A. (2016). Early warning in egg production curves from commercial hens: A SVM approach. *Computers and Electronics in Agriculture*, 161, 219–227. <https://doi.org/10.1016/j.compag.2015.12.009>
- Saar, M., Bezen, R., Edan, Y., & Halachmi, I. (2022). A machine vision system to predict individual cow feed intake using RGB-D camera and deep learning models. *Animal*, 16(2), 100443. <https://doi.org/10.1016/j.animal.2021.100432>
- Zuidhof, M. J. (2020). Precision livestock feeding: Matching nutrient supply with nutrient requirements of individual animals. *Journal of Applied Poultry Research*, 29(1), 11–14. <https://doi.org/10.1016/j.japr.2019.12.009>
- Akintan, O., Gebremedhin, K. G., & Uyeh, D. D. (2024). Animal feed formulation—Connecting technologies to build a resilient and sustainable system. *Animals*, 14(10), 1497. <https://doi.org/10.3390/ani14101497>
- Salleh, S. M., Danielsson, R., & Kronqvist, C. (2023). Using machine learning methods to predict dry matter intake from milk mid-infrared spectroscopy data on Swedish dairy cattle. *Journal of Dairy Research*, 90(1), 5–8. <https://doi.org/10.1017/S0022029923000171>
- Chhetri, K. B. (2024). Applications of artificial intelligence and machine learning in food quality control and safety assessment. *Food Engineering Reviews*, 16, 1–21. <https://doi.org/10.1007/s12393-023-09363-1>
- Devi, P., Subburamu, K., Giridhari, V. A., Dananjeyan, B., & Maruthamuthu, T. (2025). Integration of AI-based tools in dairy quality control: Enhancing pathogen detection efficiency. *Journal of Food Measurement and Characterization*, 19(7), 4427–4438. <https://doi.org/10.1007/s11694-025-03269-8>
- Bereczki-Tisza, J., & Mikó, E. (2026). AI-based visual monitoring of dairy cattle: Individual tracking and early detection of lameness through movement analysis. In *23rd Wellmann International Scientific Conference, Book of Abstracts*. University of Szeged Faculty of Agriculture.

- Kakani, V., Nguyen, V. H., Kumar, B. P., Kim, H., & Pasupuleti, V. R. (2020). A critical review on computer vision and artificial intelligence in food industry. *Journal of Agriculture and Food Research*, 2, 100033. <https://doi.org/10.1016/j.jafr.2020.100033>
- Zhao, X., Lin, C.-W., Wang, J., & Oh, D. H. (2014). Advances in rapid detection methods for foodborne pathogens. *Journal of Microbiology and Biotechnology*, 24(3), 297–312. <https://doi.org/10.4014/jmb.1310.10013>
- Law, J. W.-F., Ab Mutalib, N.-S., Chan, K.-G., & Lee, L.-H. (2015). Rapid methods for the detection of foodborne bacterial pathogens: Principles, applications, advantages and limitations. *Frontiers in Microbiology*, 5, 770. <https://doi.org/10.3389/fmicb.2014.00770>
- Gao, R., Liu, X., Xiong, Z., Wang, G., & Ai, L. (2024). Research progress on detection of foodborne pathogens: The more rapid and accurate answer to food safety. *Food Research International*, 193, 114767. <https://doi.org/10.1016/j.foodres.2024.114767>
- Banicod, R. J. S., Tabassum, N., Jo, D.-M., et al. (2025). Integration of artificial intelligence in biosensors for enhanced detection of foodborne pathogens. *Biosensors*, 15(6), 690. <https://doi.org/10.3390/bios15060690>
- Jiang, W., Liu, C., Liu, W., & Zheng, L. (2025). Advancements in intelligent sensing technologies for food safety detection. *Research*, 8, 0713. <https://doi.org/10.34133/research.0713>
- Wang, Y., & Salazar, J. K. (2016). Culture-independent rapid detection methods for bacterial pathogens and toxins in food matrices. *Comprehensive Reviews in Food Science and Food Safety*, 15, 183–205. <https://doi.org/10.1111/1541-4337.12175>
- Rejeb, A., Rejeb, K., Keogh, J. G., & Treiblmaier, H. (2022). Blockchain technology in the food industry: A review of potentials, challenges and future research directions. *Logistics*, 6, 27. <https://doi.org/10.3390/logistics4040027>
- Pérez Núñez, I., Quiñones, J., Sepúlveda Truan, G., Cancino-Baier, D., Agregán, R., Lorenzo, J. M., et al. (2026). Strategies for advanced production: A review of the use of AI in the dairy industry. *Animals*, 16(9), 1363. <https://doi.org/10.3390/ani16091363>
- Serrano-Torres, G. J., López-Naranjo, A. L., Larrea-Cuadrado, P. L., & Mazón-Fierro, G. (2025). Transformation of the dairy supply chain through artificial intelligence: A systematic review. *Sustainability*, 17, 982. <https://doi.org/10.3390/su17030982>
- Taner, O., & Çolak, A. B. (2024). Dairy factory milk product processing and sustainable shelf-life extension with artificial intelligence: A model study. *Frontiers in Sustainable Food Systems*, 8, 1344370. <https://doi.org/10.3389/fsufs.2024.1344370>
- Shi, Y., Wang, X., Borhan, M. S., Young, J., Newman, D., Berg, E., & Sun, X. (2021). A review on meat quality evaluation methods based on non-destructive computer vision and artificial intelligence technologies. *Food Science of Animal Resources*, 41(4), 563–588. <https://doi.org/10.5851/kosfa.2021.e25>
- Driessen, C., & Heutink, L. F. M. (2015). Cows desiring to be milked? Milking robots and the co-evolution of ethics and technology on Dutch dairy farms. *Agriculture and Human Values*, 32(1), 3–20. <https://doi.org/10.1007/s10460-014-9515-5>

- Sanchez, C. N., Orvananos-Guerrero, M. T., Domínguez-Soberanes, J., & Alvarez-Cisneros, Y. M. (2023). Analysis of beef quality according to color changes using computer vision and white-box machine learning techniques. *Heliyon*, 9, e17976. <https://doi.org/10.1016/j.heliyon.2023.e17976>
- Barbin, D. F., ElMasry, G., Sun, D. W., & Allen, P. (2013). Non-destructive determination of chemical composition in intact and minced pork using near-infrared hyperspectral imaging. *Food Chemistry*, 138(2–3), 1162–1171. <https://doi.org/10.1016/j.foodchem.2012.11.120>
- Alvarez-García, W. Y., Mendoza, L., Muñoz-Vílchez, Y., Nuñez-Melgar, D. C., & Quilcate, C. (2024). Implementing artificial intelligence to measure meat quality parameters in local market traceability processes. *International Journal of Food Science & Technology*, 59(11), 8058–8068. <https://doi.org/10.1111/ijfs.17546>
- Grieves, M., & Vickers, J. (2017). Digital twin: Mitigating unpredictable, undesirable emergent behavior in complex systems. In F. J. Kahlen, S. Flumerfelt, & A. Alves (Eds.), *Transdisciplinary perspectives on complex systems* (pp. 85–113). Springer. <https://doi.org/10.1007/978-3-319-38756-7>
- Tao, F., Zhang, H., Liu, A., & Nee, A. Y. C. (2019). Digital twin in industry: State-of-the-art. *IEEE Transactions on Industrial Informatics*, 15(4), 2405–2415. <https://doi.org/10.1109/TII.2018.2873186>
- Fuller, A., Fan, Z., Day, C., & Barlow, C. (2020). Digital twin: Enabling technologies, challenges and open research. *IEEE Access*, 8, 108952–108971. <https://doi.org/10.1109/ACCESS.2020.2998358>
- Wang, S., Wan, J., Li, D., & Zhang, C. (2015). Implementing smart factory of Industrie 4.0: An outlook. *International Journal of Distributed Sensor Networks*, 14(1), 1–10. <https://doi.org/10.1155/2016/3159805>
- Xu, L. D., Xu, E. L., & Li, L. (2018). Industry 4.0: State of the art and future trends. *International Journal of Production Research*, 56(8), 2941–2962. <https://doi.org/10.1080/00207543.2018.1444806>
- Samek, W., Wiegand, T., & Müller, K. R. (2017). Explainable artificial intelligence: Understanding, visualizing and interpreting deep learning models. *ITU Journal: ICT Discoveries, Special Issue*, 1(1), 1–10.
- Barredo Arrieta, A., Díaz-Rodríguez, N., Del Ser, J., Benetot, A., Tabik, S., Barbado, A., García, S., Gil-López, S., Molina, D., Benjamins, R., Chatila, R., & Herrera, F. (2020). Explainable artificial intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. *Information Fusion*, 58, 82–115. <https://doi.org/10.1016/j.inffus.2019.12.012>
- Monteiro, A., & Gökdal, Ö. (2026). Artificial intelligence applications for sustainable livestock production and environmental management: A review. *Sustainable Production and Consumption*, 45, 112–126.
- Rotz, S., Duncan, E., Small, M., Botschner, J., Dara, R., Mosby, I., Reed, M., & Fraser, E. D. G. (2019). The politics of digital agricultural technologies: A preliminary review. *Sociologia Ruralis*, 59(2), 203–229. <https://doi.org/10.1111/soru.12233>