



## Intelligent Approaches in Livestock Farming: Using Deep Learning Models

Berkant İsmail Yıldız<sup>1,a,\*</sup>

<sup>1</sup>Akdeniz Üniversitesi, Ziraat Fakültesi, Tarımsal Biyoteknoloji Bölümü, 07058, Konyaaltı, Antalya, Türkiye

\*Corresponding author

ARTICLE INFO	ABSTRACT
<p><i>Review Article</i></p> <p>Received : 13.05.2024 Accepted : 06.07.2024</p> <p><b>Keywords:</b> Machine Learning Deep Learning Artificial Neural Networks, Intelligent Agriculture, Livestock</p>	<p>Traditional animal production methods are struggling to cope with increasing population and inadequate resources. Machine learning, which has emerged as a solution to these challenges in animal production, offers various advantages in productivity, health monitoring, and breeding areas in the livestock sector. Machine learning in animal husbandry not only optimizes farm management with its significant advantages but also provides farmers with a powerful tool to achieve sustainability goals. The integration of these technological developments into the livestock sector represents a significant step towards a smarter, more efficient, and sustainable livestock practice in the future. In summary, this review provides a comprehensive exploration of the tangible benefits and innovative opportunities brought to farm animal management by machine learning methods such as deep learning and artificial neural networks. It contributes to the ongoing debate on agricultural sustainability and productivity with insights into advanced health monitoring, optimized feeding practices, and strategic breeding management.</p>

Türk Tarım – Gıda Bilim ve Teknoloji Dergisi, 12(11): 1959-1967, 2024

## Hayvancılıkta Akıllı Yaklaşımlar: Derin Öğrenme Modellerinin Kullanımı

MAKALE BİLGİSİ	ÖZ
<p><i>Derleme Makalesi</i></p> <p>Geliş : 13.05.2024 Kabul : 06.07.2024</p> <p><b>Anahtar Kelimeler:</b> Makine Öğrenmesi Derin Öğrenme Yapay Sinir Ağları Akıllı Tarım Çiftlik Hayvanları</p>	<p>Geleneksel olarak kullanılan hayvansal üretim yöntemleri, artan nüfus ve yetersiz kaynaklar ile başa çıkmakta zorlanmaktadır. Hayvansal üretimde karşılaşılan bu zorluklara çözüm olarak ortaya çıkan makine öğrenmesi, hayvancılık sektöründe verimlilik, sağlık izleme ve ıslah alanlarında önemli gelişmeler sağlayarak çeşitli avantajlar sunmaktadır. Hayvancılıkta makine öğrenimi, önemli avantajlarıyla sadece çiftlik yönetimini optimize etmekle kalmaz, aynı zamanda sürdürülebilirlik hedeflerine ulaşmada çiftçilere güçlü bir araç sağlamaktadır. Bu teknolojik gelişmelerin hayvancılık sektörüne entegrasyonu, gelecekte daha akıllı, verimli ve sürdürülebilir bir hayvancılık pratiğine doğru önemli bir adımı temsil etmektedir. Özetle, bu derleme, derin öğrenme ve yapay sinir ağları gibi makine öğrenmesi yöntemlerinin çiftlik hayvanları yönetimine getirdiği somut faydaları ve yenilikçi olanakları içeren kapsamlı bir keşif sunmaktadır. Gelişmiş sağlık izleme, optimize edilmiş besleme uygulamaları ve stratejik üreme yönetimi konularındaki içgörülerini ile tarımsal sürdürülebilirlik ve üretkenlik konusundaki devam eden tartışmaya katkıda bulunur.</p>

<sup>a</sup> [berkant yıldız@gmail.com](mailto:berkant yıldız@gmail.com) <https://orcid.org/0000-0001-8965-6361>



## Giriş

Hayvancılık, esas olarak çiftlik hayvanlarının yetiştirilmesi, yönetilmesi ve besleme uygulamaları ile ilgilenen tarım alanı olarak değerlendirilmektedir. Yıllar önce insanoğlu, hayvanları kendi çıkarları doğrultusunda evcilleştirmiştir. Evcilleştirme sürecinden günümüze kadar, hayvansal üretimde alınan yönetsel kararlar sezgisel bilgi birikimine dayanmaktadır. Fakat teknolojinin gelişmesi ile hayvansal üretimde reform sayılabilecek kararlar alınmaya başlanmıştır. Artık birçok çiftçi, hayvansal üretim ve ortak kaynakları sürdürülebilir bir şekilde kullanma konusunda ortak bir görüşte bir araya gelmektedir. Daha iyi hayvan refahıyla birlikte gelişmiş hayvan üretimine olan ilgileri, onları çeşitli ileri teknolojilere ulaşmaya zorlamaktadır (Bao & Xie, 2022).

Et ve hayvansal ürünlere yönelik artan küresel talebi karşılamak için çiftçilerin önümüzdeki 50 yıl içinde üretimi %70 oranında artırması gerekmektedir (Rojas-Downing ve ark., 2017). Arazi ve diğer doğal kaynakların sınırlı olmasından dolayı, artan talebi karşılamak için birim alanda daha fazla hayvan yetiştirmenin daha verimli yollarının bulunması gerekmektedir (Neethirajan, 2020). Bu bağlamda, geleneksel yöntemlerin artık talebi karşılamak için yeterli olmadığı ve daha etkili yöntemlere ihtiyaç duyulduğu anlaşılmaktadır. Bunun yanı sıra hayvancılıkta verimi arttırabilmenin en önemli koşullarından biri işletmedeki her bir hayvanın bireysel olarak takibini sağlamaktır, ancak bu durumun uygulanabilirliği oldukça zordur. Farklı alanlardaki teknolojik gelişmeler sayesinde hayvansal üretim yapan işletmelerdeki bireysel takip oldukça kolay hale gelmektedir. Hayvancılık alanında; nesnelerin interneti, biyosensörler için mobil uygulamaların gelişmesi ve yayılması, bireysel rasyon hazırlanması, hastalık takibi, ıslah programlarının yürütülmesi gibi unsurlar "Tarım 4.0" olarak adlandırılmaktadır. Downing Yapay zekâ tabanlı gelişmeler sayesinde birçok çiftçi hayvansal üretimde yüksek performans elde edebilmektedir (Alves ve ark., 2020).

1935 yılında Alan Turing tarafından öğrenen ve yapay zekaya dönüşebilen makine kavramı ortaya atıldı. Makine öğrenimi, insanların öğrenme süreçlerini taklit ederek zaman içerisinde geliştirilen algoritmalar yardımıyla doğruluğunu arttıran bir yapay zekâ olarak tanımlanmaktadır. Bir başka terim olan "derin öğrenme", 1986 yılında Rina Dechter tarafından bilgisayar tabanlı araştırmacılara tanıtılmıştır. Derin öğrenme; beynin yapısından ve işlevinden ilham alan, yapay sinir ağları algoritmalarını kullanarak işlemlerini gerçekleştirebilen, kendi kendine öğrenen, makine öğrenimi alt dalıdır (Parrish, 2018). Makine öğrenimi ile derin öğrenme terimleri bazen birbirinin yerine kullanılabilir ancak her ikisinin de farklı işleyişi ve metodolojisi bulunmaktadır. Temel makine öğrenimi modelleri genel olarak performansını arttırmak için rehberliğe ihtiyaç duyar fakat derin öğrenme modeli ile algoritma kendi sinir ağı sayesinde tahminin doğruluğunu belirleyebilmektedir (Khanikar ve ark., 2022). Bu bağlamda, çeşitli endüstriyel ve bilimsel uygulamalarda başarıyla kullanılan derin öğrenme yaklaşımı, akıllı hayvancılık tekniklerine yönelik ana akım yaklaşımlarda yerini almıştır. Mevcut sonuçlar, bu yöntemin klasik makine öğrenmesi modellerine kıyasla


daha fazla avantaja sahip olduğunu göstermektedir. Günümüzde çiftlik hayvanları çalışmalarında; tek nükleotid polimorfizmleri (SNP'ler), metabolik yollar, protein etkileşim ağları, gen ekspresyonu ve protein yapısı bilgilerinden oluşan büyük bir genomik veri akışı bulunmaktadır. Derin öğrenme modelleri, bu büyük veri akışının uygun bir şekilde ele alınmasında, genetik tahminlerin güvenilirliğini artırmak ve fenotip biyolojisinin daha iyi anlaşılmasını sağlamak için kullanılabilir (Nayeri ve ark., 2019).

## Yapay Sinir Ağları (YSA)


Yapay sinir ağları, gelişmiş biyolojik organizmalardaki sinir sistemi prensibine benzer çalışmaktadır. Organizmaların sinir sistemlerinde temel birim nörondur. Biyolojik nöronlar, dendrit, soma (hücre gövdesi) ve akson olmak üzere üç temel kısımdan oluşmaktadır. Nöronlar birbirlerine akson ve dendrit aracılığı ile bağlanmaktadır; bu bağlantı noktalarına ise sinaps adı verilmektedir. Dendritler, diğer birçok sinaptik öncesi nörondan veya dış ortamdan alınan sinyalleri somaya ulaştırmaktadır. Soma'ya aktarılan tüm sinyaller işlenerek bu sinyallere karşılık bir aktivasyon potansiyeli üretilmektedir. Üretilen bu aktivasyon potansiyeli, akson boyunca impulsu tetikleyip tetiklemeyeceğini belirlemektedir (da Silva ve ark., 2016). Bu aktivasyon potansiyeli, nöronun etkiye geçmesi için gerekli eşik üzerindeyse bir elektrik impulsu üretilmekte ve yayılmaktadır. İmpuls, aksonun sonuna ulaştığında sinir sistemindeki iletiyi sağlayan kimyasallar olan nörotransmitterler sinapslara salınmakta ve bu ileti süreci sonraki sinyallere doğru devam etmektedir. Bu elektriksel ve kimyasal reaksiyonlar zinciri, gelişmiş organizmaların öğrenme sürecini mümkün kılmaktadır (Hodgkin ve Huxley, 1952). Gelişmiş biyolojik canlıların sinir sistemini oluşturan bu reaksiyonlar bütünü referans alan yapay sinir ağlarının temel birimi olan yapay nöronlar ise ilk olarak 1943 yılında nörofizyolog Warren McCulloch ve matematikçi Walter Pitts tarafından geliştirilmiştir. Yapay nöronlar, biyolojik nöronları temel olarak yapay sinir ağlarını oluşturmak için programlanmış bir fonksiyondur (Kubat, 2020).

Şekil 1' de gösterildiği üzere, yapay bir nöronun pozitif ve negatif değerlere sahip  $W_1, W_2, W_3, W_n$  ağırlıkları ve nörona bağlanan  $I_1, I_2, I_3, I_n$  giriş sinyalleri bulunmaktadır. Nöronun sinyal ağırlıkları, yapay sinir ağına sunulan eğitim setlerine göre değişen, ayarlanabilir parametreler olup, giriş sinyallerinin gücünü de belirlemektedir. Postsinaptik nörondaki belirli bir sinapsın etkisi,  $I_i W_i$  ile verilmektedir ve bu kombinasyonun toplamı ( $\sum I_i W_i$ ), nöronun eşik değeri ile karşılaştırılarak, nöronun tetiklenip tetiklenmeyeceği tespit edilmektedir. İşlenen bu girdi, çıktıya dönüştürülerek bir sonraki nörona iletilmektedir. Hayvancılık sektöründe oldukça yaygın olan çok katmanlı sinir ağları, birden fazla hesaplama katmanını içermektedir. Şekil 2' de gösterildiği üzere, yapay sinir ağını oluşturan 3 ayrı bölüm bulunmaktadır. Yapay sinir ağında öğrenme süreci, ağı parametrelerinin ağırlıkları ( $W_{ij}$ ) ve sapmaları ( $b_j$ ) ile başlamaktadır. Daha sonra, nöronlar bir dizi girdi verisi örneği olarak, tahminlerini elde etmek için bunları ağı üzerinden

geçirmektedir. YSA, bu tahminleri karşılaştırmakta ve oluşan kaybı hesaplamaktadır. Hesaplanan kayıp giriş katmanındaki her bir parametreye dağıtmak için geri yayılım (bilginin geri yönlü akışı) fonksiyonunu gerçekleştirmektedir. Sinyal ağırlıkları, girdi parametrelerinin toplam kaybını en aza indirecek şekilde güncellemek için bu yeni oluşturulan bilgiyi uygulamaktadır. YSA, modelin iyi olduğunu kabul edene kadar önceki adımları tekrarlamaya devam etmekte ve bu sayede yapay sinir ağları doğruluk elde etmektedir (Krogh, 2008).



Şekil 1. Yapay nöronun yapısı  
Figure 1. Structure of the artificial neuron



Şekil 2. Yapay sinir ağının yapısı  
Figure 2. Structure of the artificial neural network

### Toplama Fonksiyonu

Bir yapay sinir ağında, gelen girdilerin çarpımlarının toplamı sonucu elde edilen net girdi değerinin hesaplanması, toplama fonksiyonu olarak ifade edilmektedir. Bazı durumlarda, YSA'ya gelen girdilerin değeri dikkate alınırken, bazı durumlarda ise gelen girdilerin sayısı önemli olabilmektedir. Bir problemde sonuç elde edilmeye çalışırken, tek tip bir toplama fonksiyonu bulunmamaktadır. Her problemin kendine uygun toplama fonksiyonu, deneme yanılma yolu ile tespit edilmektedir (Richert, 2013). Toplama fonksiyonu aşağıdaki gibi ifade edilmektedir:

$$\sum_{i=1}^n (wijxi + bj)$$

$wij$ :  $i$  indeksi ile belirtilen girdinin ağırlığı,  $xi$ :  $i$  indeksi ile belirtilen giriş,  $bj$ :  $j$  indeksi ile belirtilen nöronun bias değeri

Toplam fonksiyonu kullanılarak elde edilen değer, lineer veya lineer olmayan türevlenebilir bir aktivasyon

fonsiyonundan geçirilen işlem elemanının çıktısı, aşağıdaki gibi ifade edilebilmektedir (Yavuz & Deveci, 2012):

$$y = f(zi) = f\left(\sum_{i=1}^n (wij xi + bj)\right)$$

$y$ : Çıkış değeri veya çıkış değişkeni,  $f(zi)$ : Aktivasyon fonksiyonunun  $zi$  girişine uygulanmasıyla elde edilen çıkış değeri,  $zi$ : Giriş değerlerinin ağırlıklı toplamı

Aktivasyon fonksiyonu, nöron davranışını belirleyen en önemli etmenlerden biridir. YSA' da nöronun çıkış değeri, istenilen değerler arasına sınırlanmaktadır. Genel olarak bu değerler (0, 1) veya (-1, 1) değerlerinden oluşmaktadır (Sağiroğlu ve ark., 2003). Aktivasyon fonksiyonu, nörona gelen net girdinin işlenerek nöronun bu girdiye karşılık üreteceği net çıktıyı belirlemektedir. Aktivasyon fonksiyonu için genellikle lineer olmayan bir fonksiyon kullanılmaktadır ve yaygın olarak tercih edilen fonksiyonlar ise; doğrusal (lineer), sigmoid, bipolar sigmoid ve hiperbolik tanjant aktivasyon fonksiyonlarıdır. Toplam fonksiyonundan çıkan sonuç, belirli bir katsayı ile çarpılarak hücrenin çıktısını oluşturmaktadır. Sigmoid aktivasyon fonksiyonu ise sürekli ve türevi alınabilir bir fonksiyon olup, girdi değerlerinin her biri için "0" ile "1" değeri arasında bir değer üretmekte olup aşağıdaki gibi ifade edilmektedir (Çayıroğlu, 2015):

$$F(Net) = \frac{1}{1 + e^{-Net}}$$

$F(Net)$ : Aktivasyon fonksiyonunun  $Net$  girişine uygulanmış hali,  $e$ : Euler sayısı,  $Net$ : Girişin ağırlıklı toplamı

Bipolar Sigmoid aktivasyon fonksiyonu, önem sırasına göre kademeli bir ağ yapısı oluşturmak için geliştirilmiştir. Fonksiyonun sağladığı etkileştirme işlevi ağırlıklarının -1 ve +1 aralığında tutmaktadır ve hatayı en aza indirmek için tasarlanmıştır. Bu fonksiyon aşağıdaki gibi hesaplanmaktadır (Kaur & Gupta, 2020):

$$F(Net) = \frac{1 - e^{-2Net}}{1 + e^{-2Net}}$$

$F(Net)$ : Aktivasyon fonksiyonunun  $Net$  girişine uygulanmış hali,  $e$ : Euler sayısı,  $Net$ : Girişin ağırlıklı toplamı

Hiperbolik tanjant aktivasyon fonksiyonu da sigmoid fonksiyonuna oldukça benzer yapıdadır ancak hiperbolik tanjant fonksiyonunda çıkış değerleri -1 ile +1 değerleri aralığında olmaktadır (Çayıroğlu, 2015). Aşağıdaki gibi ifade edilmektedir (Öztemel, 2012; Alp & Öz, 2019):

$$F(Net) = \frac{e^{Net} - e^{-Net}}{e^{Net} + e^{-Net}}$$

$F(Net)$ : Aktivasyon fonksiyonunun  $Net$  girişine uygulanmış hali,  $e$ : Euler sayısı,  $Net$ : Girişin ağırlıklı toplamı

### Geri Yayılım Algoritması

Yapay sinir ağlarında, önemli problemler geri yayılım algoritmaları ile çözülmektedir. Geri yayılım ağında, gizli katmandaki ve çıktı katmanındaki hataların geriye yayılması ile belirlenmektedir. Geri yayılım algoritmalarında, sigmoidal transfer fonksiyonu yardımı ile doğrusallıktan ayrı birden fazla çıktı birimi kullanılabilir. Çıktı birimleri ise -1 ila +1 aralığında reel sayılar üretebilmektedir (Kröse & Smagt, 1996). Aşağıdaki gibi ifade edilmektedir:

$$\Delta w_{ij} = -\eta \frac{\partial E}{\partial w_{ij}}$$

$\Delta w_{ij}$ : Ağırlık güncellemesi,  $\eta$ : Öğrenme hızı (learning rate),  $\frac{\partial E}{\partial w_{ij}}$ : Hata fonksiyonunun  $w_{ij}$  ağırlığına göre kısmi türevi

### Algoritma Uygunluk Kriterleri

Yapay sinir ağı algoritma performansı genellikle, Hata Kareler Ortalaması (MSE) ve Ortalama Mutlak Hata (MAE) ile tespit edilmektedir. MSE ve MAE aşağıdaki gibi hesaplanmaktadır (Gültekin & Doğan, 2023):

$$MSE = \frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}$$

$$MAE = \frac{\sum_{i=1}^n |Y_i - \hat{Y}_i|}{n} = \frac{\sum_{i=1}^n |\epsilon_i|}{n}$$

$n$ : Veri noktalarının toplam sayısı,  $Y_i$ : Gerçek değerlerin  $i$  indeksi ile belirtilen elemanı,  $\hat{Y}_i$ : Tahmin edilen değerlerin  $i$  indeksi ile belirtilen elemanı,  $\epsilon_i$ : Hata terimi,  $i$  indeksi ile belirtilen elemanı

### Hayvancılıkta Derin Öğrenme Modellerinin Kullanımı

Hayvansal üretimde derin öğrenme yöntemleri, son yıllarda endüstride reform niteliğinde bir etkiye sahip olmuştur. Bu teknikler, hayvan davranışlarını izlemek, hastalıkları teşhis etmek, verimliliği artırmak ve genel olarak üretim süreçlerini optimize etmek için kullanılmaktadır. Özellikle, derin öğrenme algoritmaları, büyük veri setlerinden öğrenerek karmaşık ilişkileri belirleyebilecek ve geniş ölçekte hayvancılıkta kullanılabilir potansiyele sahiptir. Bununla birlikte, arıcılık sektöründe derin öğrenme tekniklerinin benimsenmesi, arı kolonilerinin sağlığını izlemek ve yönetmek için yeni olanaklar sunmaktadır. Dünya genelinde bal arısı popülasyonunun azalması, koloni gücünün değerlendirilmesini ve sürdürülebilir arıcılığın önemini giderek artırmaktadır (Alves ve ark., 2020). Kovan içerisindeki larva ve gıda rezervleri ile ilgili yapılan zaman içerisindeki tespitler, araştırmacılara koloni dinamiklerini modelleme ve arıcılar için koloni gücü hakkında bilgi sağlamakta; ayrıca, bal veriminin bir göstergesi olarak da hizmet etmektedir. Kovan içerisindeki hücreleri manuel olarak saymak, yoğun işgücü gerektirmekte ve hata payının artmasına sebep olmaktadır. Bu durumdan kaynaklı olarak, Alves ve ark. (2020) yapmış olduğu bir çalışmada, DeepBee© adını verdikleri kovan

görüntülerini otomatik olarak tespit edebilen ve yumurta, larva, kapalı larva, polen, nektar, bal ve hücrelerdeki diğer içerikleri ayırt edebilen yapay zekâ tabanlı bir uygulama geliştirmişlerdir. Geliştirilen bu uygulama, Circle Hough dönüşümü ve anlamsal bölütleme tekniğini kullanarak, literatürde yayınlanmış en iyi sonuçtan (%16,2) daha iyi bir sonuç ile (%98,7) hücre tespit edilmiştir. Geliştirilen bu uygulama ile kovan sağlığının daha iyi tespit edilmesi sağlanmıştır. Arılarda yapılan diğer bir çalışmada ise Berkaya ve ark. (2021), bal arılarının polen toplama verimliliği ile ilgili davranışsal araştırmalara odaklanmıştır. Polen toplama verimliliği, bal arıları üzerinde davranışsal araştırmalar için önemli konuların başında yer almaktadır. Arı kovanlarının polen üretimi, polen tuzaklarından toplanan polenlerin manuel olarak tartılması ile ölçülebilmektedir. Uzun vadede bakıldığında, yapılan bu işlem hem verimsiz hem de iş gücü açısından zahmetli olmaktadır. Bu konuda yapılan bir çalışmada, sabit bir görüntüleme sistemi aracılığı ile polen toplama davranışını ve çevre koşullarını otomatik olarak tespit edebilen bir sistem geliştirilmiştir. Bu çalışmada, arı kovanına kurulan bir kamera yardımıyla, nesne izleme algoritması tarafından desteklenen gerçek zamanlı nesne algılama ve derin öğrenmeye dayalı sınıflandırma modeli, bal arılarını polenli ve polensiz sınıfa ayırmak için eğitilmiştir. Arı kovana girişinde kaydedilen bal arısı giriş ve çıkış trafiğine dayanarak, hava koşullarının bal arısı besin arama davranışı üzerindeki etkilerini incelemek için çeşitli endeksler türetilmiştir. Bu endeksler polen toplama davranışını iyi yansıtmakta olup, bal arısı kolonilerinin durumuna ilişkin daha nicelikli bilgi sağlamaktadır. Yapılan bu çalışmada, günlük polen toplama gezi oranı %24,5 ± 3,5 olarak hesaplandı ve bu oran %17,5 ila %32,5 arasında değişim göstermiştir. Yapılan bu çalışmada ortalama olarak tek bir arı kovana günde yaklaşık olarak %49,1 ± 11,0 g polen toplandığı bildirilmiştir. Deneysel sonuçlar ve analizler, sıcaklığın, bağıl nemin, ışık yoğunluğunun, yağışın ve rüzgâr hızının polen gezinim sayılarını önemli ölçüde etkilediğini ortaya koymaktadır. Şiddetli yağmur ve hafif esinti koşullarında polen toplama faaliyetlerinde önemli bir azalma gözlemlenmiştir. Sonuç olarak önerilen bu sistem işlevsellik ve doğruluk açısından diğer mevcut polen toplama davranışı izleme sistemlerinden daha iyi performans göstermiştir. Arılarda kovan içi huzur ve refahın artması, üretim performansını doğrudan etkileyen bir konu olduğundan, yapay zekâ tabanlı teknolojilerin hastalık takibi alanında kullanımı da giderek artmaktadır. Arıcılıkta önemli sorunların başında gelen koloni çöküş bozukluğunun birincil sebebi olarak Varroa akarı görülmektedir. Voudiotis ve ark. (2022), Varroa istilasının erken tespit süreci için derin öğrenme algoritmasıyla desteklenen sabit bir kamera modülü kullanmışlardır. Bu düzenek, akarı taşıyan kuluçka çerçeveleri içindeki arıları gerçek zamanlı olarak tespit etmeyi amaçlamıştır. Önerilen derin öğrenme algoritması, arıyı tespit etmek için bir derin öğrenme ağını ve daha önce tespit edilen nesnelere akarı tanımlamak için bir görüntü işleme adımı kullanmıştır. Araştırmacılar, Varroa akarı tespit sürecini ve gerçek Varroa vakalarında tespit algoritmalarının doğruluğunun ve kesinliğinin sırasıyla %77 ve %86 olarak değerlendirilmesini sağlamışlardır. Yapılan çalışmada araştırmacılar, kullanılan algoritmanın Varroa vakalarında değerlendirilmesi gerektiğini

savunmuşlardır. Arılar, dünyada sürdürülebilirliği sağlayan etkenlerin en başında gelmektedir. Bundan dolayı, araştırmacıların arıların birbirleri ile olan etkileşimlerini anlamak oldukça önemli bir yer teşkil etmektedir. Arılar, hacim olarak küçük beyinleri olmasına rağmen zengin bir davranış repertuarına sahip olmalarının yanı sıra bireyler arasında önemli farklılıklar göstermektedirler. Sosyal arılarda bu değişkenlik, karmaşık sosyal organizmalarını sürdüren iş bölümünün anahtarı olmakla birlikte gelişim ve besin arama deneyiminin bir sonucu olarak belirli beyin alanlarının olgunlaşmasıyla bağlantılıdır. Bu durum, arıları böceklerin bilişsel işlevlerini ve bunların altında yatan sinir mekanizmalarını anlamak için ideal bir model haline getirmektedir. Karşılaştırmalı verilerin azlığı nedeni ile beyin nöromimarisi ve davranışsal değişkenlik arasındaki ilişki belirsizliğini korumaktadır. Bu soruna çözüm olması açısından Lösel ve ark. (2023) tarafından yapılan bir çalışmada, 187 bal arısı ve yaban arısı beyninden alınan 3 boyutlu görüntü verilerinin otomatik analizini gerçekleştirmek için mikro bilgisayar tomografisi (mikro-BT) ve derin öğrenme kullanılmıştır. Yapılan araştırma sonucunda, toplam beyin boyutunda, koloni ve türler arasında tutarlı olan sonuçların yanı sıra sosyal organizasyonların merkezinde yer alan davranışsal değişkenliği destekleyebilecek bireyler arası güçlü farklılıklar ortaya konmuştur. Bu duruma ek olarak, yaban arısı veri setinden elde edilen bilgilere dayanarak optik ve anten beyin loplarda önemli düzeyde lateralizasyon gösterdiği tespit edilmiştir. Bu durum yaban arılarının görsel ve koku alma öğrenmesindeki farklılıkları destekler nitelik taşımaktadır. Yapılan bu araştırma sayesinde, bilinen davranışlarla ilişkili olan ve daha önce tanımlanmamış anatomik özellikler tanımlanarak, arıların besin arama ve tozlaşmada yanal davranışlara dair kanıtları desteklemektedir. Bal arıları, en önemli tozlayıcı olmasından kaynaklı olarak doğal ekosisteme önemli katkılarda bulunmaktadır. Bir kovadaki binlerce arının birbiriyle iletişim kurmasının sayısız yolu bulunmaktadır. Polen, su ve nektar toplamak için kovana dışına çıkan tarlacı arılar, kovana döndüklerinde diğer arılara nektarın yerini bildirmek için farklı ve alışılmamış olan çeşitli dans figürleri sergilemektedir (sallantı ve çember dansı gibi). Dolayısıyla, bireysel yörengelerin ve sosyal etkileşimlerin ekolojik bir çalışma için değerli bilgiler sağlayabilmektedir. Bal arısı davranışı incelemek için güvenilirliği tartışma konusu olan çalışmalardan kaynaklanan zorlukların arasında karmaşıklık, arka plan sahnelerinin çeşitliliği, bireysel arı hareketlerinin dinamikliği ve arılar arasındaki benzerlik yer almaktadır. Bal arısı davranışını incelemek ve daha güvenilir sonuçlar elde etmek amacıyla, derin öğrenme algoritmaları ve Kalman filtresi kullanılarak bir arı kovası ortamındaki arıların bireysel takibini amaçlayan bir çalışma yapılmıştır. Kongsilp ve ark. (2024) yapmış oldukları çalışmada, birden fazla arının tespit edilmesi için ResNet-101 sinir ağına sahip Mask R-CNN kullanmıştır. Daha sonra Kalman filtresi, her bir arının gövdesini bir dizi görüntü karesi boyunca takip ederek, birden fazla arıyı takip etmek için kullanmıştır. Çalışma sonucunda, bal arısının bireysel ve sosyal iletişimi için kullandığı dans figürlerinin doğru bir şekilde tespiti sağlanmıştır. Bu durumdan yola çıkarak, derin öğrenme algoritmalarının arıcılık sektöründe

karmaşık olan alanlarda elde edilecek sonucun tespitinde ve güvenilirliğinde daha iyi neticeler verdiğini gösterir niteliktedir.

İnsan beslenmesinde hayvansal proteinin büyük ölçekte karşılandığı alanlardan biri olan beyaz etin büyük çoğunluğu tavuklardan karşılanmaktadır. Tavuk yetiştiriciliği, gıda endüstrisinde önemli bir rol oynayan ve dünya genelinde yaygın olarak yapılan bir faaliyettir. Günümüzde, tavuk yetiştiriciliği endüstrisi giderek daha karmaşık hale gelmekte ve verimliliği artırmak, hastalıkları teşhis etmek, refahı izlemek ve tesis yönetimini optimize etmek gibi birçok zorluğa maruz kalmaktadır (Dac ve ark., 2022). Bu zorlukların üstesinden gelmek için, derin öğrenme gibi yapay zekâ teknolojileri giderek daha fazla kullanılmaktadır. Derin öğrenme, büyük veri kümelerinden öğrenme yeteneğiyle bilinen yapay sinir ağları temelli bir öğrenme yaklaşımıdır (goodfellow ve ark., 2016). Tavuk yetiştiriciliği alanında, derin öğrenme yöntemleri, nesne tanıma, hastalık teşhisi, davranış izleme ve üretim süreçlerinin otomatikleştirilmesi gibi çeşitli uygulamalarda kullanılmaktadır. Örneğin, tavuk çiftliklerindeki kameralar aracılığıyla elde edilen görüntüler, derin öğrenme algoritmaları tarafından analiz edilerek tavukların sağlık durumu ve davranışları hakkında değerli bilgiler elde edilebilmektedir. Bunun yanı sıra, derin öğrenme modelleri, tavuk hastalıklarını teşhis etmek için klinik semptomları tanıma ve tanı yöntemlerini geliştirme konusunda da potansiyel taşımaktadır. Tavuk yetiştiriciliği alanında derin öğrenme tekniklerinin kullanımı, endüstrinin daha verimli, sürdürülebilir ve hayvan refahını gözeten bir yapıya dönüşmesine katkı sağlayabilecektir. Bölgelere göre değişmekle birlikte, tavuk yetiştiriciliği önemli ekonomik getirilerin başında gelmekte olup önemli bir protein kaynağıdır (Lasekan, 2013). Etlik piliçlerin yetiştirildiği geleneksel bir tavuk çiftliğinde, yetiştiricilerin genellikle piliçlerin sağlığını tespit edebilmek için her gün düzenli periyotlar ile manuel olarak gözlemlenmeleri gerekmektedir. Yetiştiriciler, kümes içerisindeki ölü tavukları tespit ettiklerinde bakteriyel ve viral etmenlerin yayılmasını önlemek için manuel olarak toplamak durumundadırlar. Ancak bazen bu durum yetiştiricilerin gözünden kaçarak hastalık etmenlerinin bütün çiftliğe yayılması ile sonuçlanan durumlar yaşanmaktadır. Bu durumdan kaynaklı yapılan bir çalışmada Liu ve ark. (2021), derin öğrenme tabanlı görüntü işleme algoritmalarından yararlanılarak tasarlanan otomasyon sistemi geliştirmişlerdir. Kameralar ile izlenen kümeslerdeki ölü tavuklar, YOLOv4 algoritmasına dayalı derin öğrenme yoluyla tespit edilerek mekanik sisteme verilen emir ile süpürülerek toplanmaktadır. Çalışmada tasarlanan bu sistemin hassasiyeti %95,24 olarak tespit edilmiştir. Tasarlanan bu sistem, kümes içerisindeki ölü tavuklarının tespit edilip uzaklaştırılmasının yanı sıra ölü hayvan ile insan arasındaki teması azaltarak muhtemel hastalıklarında önüne geçen bir sistem olmuştur. Bu durumdan dolayı hayvan sağlığının izlenmesi, hayvan refahının ve yaşam alışkanlıklarının toplanmasına olanak tanımakta olup hayvan yetiştiriciliğinde hassasiyeti arttırmaktadır. Bu bilgilerin ışığında yapılan diğer bir çalışmada Guo ve ark. (2022), farklı yaşlardaki tavukların davranışlarını izlemek için derin öğrenmeye dayalı algoritmalar kullanmıştır. Çalışmada, tavukların 2, 9, 16 ve 23. Günlerdeki üstten görünüşleri elde edilmiştir. Her

aşamada, tavukların dört davranışının (beslenme, içme, ayakta durma ve dinlenme) her birine ait 300 görüntü bölümlere ayrılarak toplamda 4800 görüntü elde edilmiştir. Görüntü büyütme işleminden sonra her gün için 8000 eğitim seti, 2000 doğrulama seti ve 200 test seti dahil 10200 görüntü üretilerek farklı evrimsel sinir ağı modellerinin (CNN) tavuk davranışlarının tanımlanmasındaki performansı analiz edilmiştir. Araştırma sonucunda, kullanılan sinir ağı modellerinden DenseNet-264 ağının genel performansının, 2, 9, 16 ve 23 günlük tavuklarda sırasıyla; %88,5, %97, %94,5 ve %90 doğruluk oranlarıyla kullanılan sinir ağları içerisinde en doğru model olduğu tespit edilmiştir. Farklı günlerdeki tavukların davranışlarının tespit edilmesi, tavuk biyolojisi ve psikolojisi hakkında daha çok bilginin elde edilmesi anlamına gelmektedir. Ayrıca ileride kurulacak modern kümeslerin daha verimli sonuçlar elde etmesine olanak tanıyacağı ön görülmektedir. Hayvanlardaki hastalıkların kümes içerisinde erken teşhis edilmesi, verim kaybını ve oluşabilecek zoonoz riskinin önlenmesi için son derece önemlidir. Bu konu ile ilgili yapılan bir çalışmada Gourisaria ve ark. (2023), “Salmonella”, “Koksidiyoz”, “Sağlıklı” ve “New Castle Hastalığı” kategorik sınıflandırması için çeşitli CNN modelleri uygulamış ve orana göre verimlilik esas alınarak en iyi modeli seçmiştir. Tavuk hastalığı tespiti için toplam 7 CNN modeli ile 5 derin öğrenme algoritması kullanılmıştır. Önerilen ChicNetV6 modeli, toplam 1125 saniyelik eğitim süresi ile 2,8198 verimlilik puanı ve 0,9449 doğruluk puanı elde ederek en iyi sonuçları göstermiştir. Yapılan bu çalışma hayvansal üretimde verimliliği artırarak zoonoz riskinin önlenmesini sağlamaktadır. Nesne tabanlı derin öğrenme yöntemi kullanılarak yapılan başka bir çalışmada ise etlik piliç endüstrisindeki verimliliğin artırılması hedeflenmiştir (Sun ve ark., 2024). Etlik piliç endüstrisinde fenotipin belirlenmesi kritik öneme sahiptir. Bacak ağırlığı, ıslah kriteri için temel bir gösterge olup, invaziv olmayan test teknolojisi hayvanlara verilen zararı azaltabilmektedir. Sun ve ark. (2024) tarafından yapılan çalışmada, bir ağırlık tahmin modeli ve bilgisayarlı tomografi (CT) ekipmanından oluşan bir tavuk bacak ağırlığı tahmin sistemi geliştirilmiştir. Ağırlık tahmin modeli, CT ekipmanı ile canlı tavukların tarama sonuçlarını otomatik olarak işleyebilmekte ve YOLOv5 segmentasyon algoritmasına ve rasgele orman algoritmasına sahiptir. Yapılan çalışma sonucunda 25 tavuğun 50 ayrı bacağı üzerinde yapılan testlerde 7,27 g ortalama mutlak hata ve %4,82 ortalama yüzde hata sergilediği tespit edilmiştir. Etlik piliçlerin bacak ağırlıklarının tahmininde R<sup>2</sup> tahmini %88,98'e ulaştığı tespit edilmiştir. Kurulan bu sistem, etlik piliç üretimi yapan işletmeler için bölgesel bazlı yapılan üretimin kalitesini arttırdığı gözlemlenmiştir.

Yapay zekâ alanında gelişmeler son yıllarda hayvancılığın yanı sıra veterinerlik bilimlerinde karşılaşılan analitik zorluklara da çözümler sağlamıştır (Cihan ve ark., 2021). Dünya çapında yaklaşık olarak bir milyardan fazla koyun bulunmaktadır (Morris, 2017). Gelişmiş ülkelerdeki sayılarına ve varlıklarına rağmen koyun çiftlikleri, sığırlara kıyasla nispeten geleneksel yaklaşımlarla yönetilmektedir (Morrone ve ark., 2022). Geleneksel yetiştiricilikteki insan gücü, otlatma alanlarının kalitesizliği, yetersiz yetiştirme ve genetik gelişim, yüksek

yem maliyetleri, hayvan sağlığı sorunları ve olumsuz çevresel etkiler gibi doğrudan kaliteyi etkileyen faktörler hayvansal üretimi zorlaştırmaktadır. Bu durumlara ek olarak çoğu geleneksel hayvan çiftliklerinde kayıt tutma sisteminin bulunmaması, hayvan sağlığını, soy bilgisini, etkili sürü yönetimini ve performansın izlemeyi imkânsız hale getirmektedir (Aldridge ve ark., 2019). Bu amaçla koyun yetiştiriciliğinde maliyetleri ve gelirleri optimize ederek karlılığı en üst düzeye çıkarabilmek için hayvan refahının iyileştirilmesi doğrudan yüksek verimle bağlantılı olduğundan, çiftçilerin koyun çiftliklerinde yapay zekâ tabanlı dijitalleşmeyi benimsemeleri teşvik edilerek veriye dayalı çiftçiliğin yapılması çiftlikteki karar verme mekanizmasının daha doğru yürütülmesini sağlamaktadır (Jiménez ve ark., 2019). Koyunları yırtıcı hayvanlardan korumak ve yönetmek için köpeklerin kullanılmasının eski zamanlardan beri oldukça etkili olduğu tespit edilmiştir (Zingaro ve ark., 2018). Bununla birlikte, bu yaklaşımın özellikle koyunların savunmasız ve sosyal doğasından dolayı, yüksek kortizol seviyeleri ile karakterize edilen kronik stresi tetiklediği gözlemlenmiştir (Terlouw ve ark., 2008). Bu stresin yansımaları, koyunlarda fiziksel yaralanmalardan düşüklere kadar birçok olumsuz etkilere sebep olmaktadır (Phythian ve ark., 2011). Sonuç olarak çoban köpeklerinin varlığının koyunlar üzerinde sebep olduğu olumsuz etkileri azaltabilmek için alternatif bir sistem olan otonom çobanlık sistemlerinin yapay zekâ ile entegrasyonu sunulmaktadır (Beausoleil ve ark., 2012). Drone'lar bu amaç doğrultusunda araştırılarak, “gökyüzü çobanlığı” olarak adlandırılan kavram ortaya çıkmıştır. Yaxley ve ark. (2021) yapmış olduğu bir çalışmada, çiftlik koyunları arasındaki stresi azaltmak için çoban köpekleri yerine Drone'ları kullanmışlardır. Yapılan çalışmada drone'lar, koyun sürülerinden belirli tepkiler almak için çeşitli işitsel sinyaller verecek şekilde programlanmışlardır. Ek olarak gece oluşabilecek tehlikeleri tespit etmek ve izinsiz giriş durumunda alarm vermek için termal kızılötesi kameralarla donatılmış drone'lar kullanılmıştır (Bondi ve ark., 2019). Kullanılan başka bir biyometrik gözetim sistemi ise koyunlara çobanlık yaparken dış etmenlerden karşı korur, hassas ve kısıtlı alanlara girmelerini engelleyerek değişen çevre koşullarına uyum sağlayabilmektedir (Strömbom & King, 2018). Koyun yetiştiriciliği sektöründe bir diğer olumsuzluk ise hastalıkların tespit edilerek uygun tedavi yöntemlerinin uygulanmasıdır. Bu konuda yapay zekâ destekli yapılan çalışmalar potansiyel sağlık sorunlarının belirlenmesine olanak sağlayarak hızlı bir şekilde gelişmektedir. Örneğin yapılan bir çalışmada, histoloji verilerini değerlendirmek için yapay zekanın uygulanmasına odaklanmış ve yerleşik fare intervertebral disk (IVD) dejenerasyon modelinde dikkate değer bir iyileşme ile sonuçlanmıştır. Bu sistem aynı zamanda koyunlarda dejeneratif IVD değişikliklerinin tespit edilmesi konusunda da ümit vaat etmektedir (Alimi ve ark., 2018). Ek olarak derin öğrenme yaklaşımlarının uygulanmasıyla koyunlarda solunum yolu hastalıklarının erken tespiti mümkün hale gelmiştir (Cowton ve ark., 2018). Ayrıca, yapay zekâ üzerine inşa edilen Digital Twin (DT) teknolojisi, çiftlik hayvanlarının kalp atışlarının analizinde %92 oranında yanıtı ulaşılarak hastalık analizini ve tahminini iyileştirmede önemli bir potansiyel

göstermiştir (Mishra & Sharma, 2023). Yapay zekâ araçlarının klinik mikrobiyoloji ve parazitoloji laboratuvarlarına entegrasyonu, kesin, hassas ve hızlı sonuçlar sağlayabilen umut verici bir alternatif olarak ortaya çıkmıştır. Bir grup araştırmacı, dijital slayt taramasını yapay zekâ ile birleştirerek, pozitif ve negatif trikrom slaytları ayırt edebilen bir evrimsel sinir ağı (CNN) modeli geliştirmişlerdir ve bu model, manuel incelemeye kıyasla üstün hassasiyet ve doğruluk göstermiştir (Mathison ve ark., 2020). Başka bir çalışmada ise *Schistosoma haematobium* yumurtalarını tespit etmek için otomatik olarak mikroskopik slaytlara odaklanan ve bunları tarayan eğitilmiş bir derin öğrenme sinir ağı modelinden yararlanılmıştır (Oyibo ve ark., 2022). Ulusal ekonomilerin sürdürülebilir kalkınması için temel sektörlerden bir diğeri ise keçi yetiştiriciliğidir. Jiang ve ark. (2020), grup halinde barındırılan keçilerin üstten görünüm videolarından yeme, içme, aktif ve pasif davranışlarını tanımak için derin öğrenme kullanarak etkili bir davranış tanıma yaklaşımı önermişlerdir. İlk olarak, bireysel keçilerin algılanma yaklaşımı, birkaç popüler derin öğrenme yönteminin özelliklerini ve uygunluğunu araştırarak tasarlanmıştır. İkinci olarak, üst görünüm videolarından grup içinde barındırılan keçilerin genel davranış tanıma çerçevesini önermişlerdir. Dört tip keçi davranışı, keçi sınırlayıcı kutuları ile besleme alanları arasındaki mekansal konum ilişkisi analiz edilerek tanınmıştır. Ayrıca, aynı keçinin sınırlayıcı kutu merkezlerinin ardışık kareler arasındaki zaman içindeki hareket miktarı incelenerek tanınmıştır. Deneysel sonuçlar, YOLOv4'ün hem keçi algılama hızı hem de doğruluğu açısından diğer modellere göre daha üstün olduğunu göstermiştir. Yeme, içme, aktif ve pasif davranışlar için sırasıyla %97.87, %98.27, %96.86 ve %96.92 ortalama tanıma doğrulukları, deneysel videolarda, geleneksel bir donanım yapılandırmasında saniyede 17 kare ortalama analiz hızıyla gerçek zamanlı olarak elde edilmiştir. Dolayısıyla, önerilen yaklaşımın grup içinde barındırılan hayvanların kapsamlı davranış tanımasını otomatik olarak gerçekleştirmenin etkili bir yolunu sunabileceği gösterilmiştir.

İnsansız hava araçları (İHA), çiftliklerin yönetimine her geçen gün daha yardımcı olmaktadır. Derin öğrenmenin özellikle de evrimsel sinir ağlarının (CNN) ortaya çıkışıyla birlikte, hava görüntülerinden ilgili bilgilerin çıkarılması daha etkili hale gelmiştir. Bu bağlamda Barbedo ve ark., (2019) tarafından yapılan bir çalışmada, 3 araştırma sorusu ortaya çıkarılmıştır: (1) Nelore cinsine (*Bos taurus indicus*) görsel olarak benzeyen Canchim cinsine ait hayvanların tespitinde elde edilecek mümkün olan en yüksek doğruluğu belirlemek; (2) hayvan tespiti için ideal zemin numunesi mesafesini (GSD) belirlemek; (3) bu özel problem için en doğru CNN mimarisini belirlemek. Yapılan deneylerde, 8629 hayvan örneği içeren 1853 görüntüyü içeren 15 farklı CNN mimarisi test edilmiştir. Toplam 900 model eğitilmiştir (15 CNN mimarisi  $\times$  3 uzaysal çözünürlük  $\times$  2 veri seti  $\times$  10 kat çapraz doğrulama). İHA'lar kullanılarak çekilen havadan görüntüler kullanılarak sığırların tespitini etkileyen çeşitli hususların derinlemesine analizi yapılmıştır. Araştırma sonucunda, birçok CNN mimarisinin ideal koşullardan uzak olsa bile hava görüntülerindeki hayvanları güvenilir bir şekilde tespit edebildiğini ortaya koymuştur. Yapılan başka bir çalışmada ise Bezen ve ark. (2020) tarafından, CNN

modelleri ve RGB-D (Kırmızı, Yeşil, Mavi, Derinlik) kamerasına dayalı, sığırların bireysel yem alımı ölçümü için bir bilgisayarlı görme sisteminin tasarımı ve uygulaması gerçekleştirilmiştir. Süt sığırlarının bireysel yem alımı, ticari süt işletmelerinde şu andan mevcut olmayan önemli bir değişkendir. Çalışmada, 26 saatlik bir süre boyunca yem yiyen sığırların görüntüleri, sığırın tanımlanması için test verilerini sağladı ve sistem sığırların %93,65'ini doğru bir şekilde tanımlamayı başarmıştır. Ögün başına 0-8 kg arasında değişen tüketilen yem miktarı, 0,127 kg ve 0,034 ortalama mutlak ve karesel hatalar (MAE ve MSE) ile ölçülmüştür. Analiz, veri miktarının ve çeşitliliğinin model eğitimi için önemli olduğunu göstermiştir. Bu çalışmanın sonucu olarak, gelişmiş süt çiftliklerinde bireysel yem alımı ölçümlerinin düşük maliyetli kameraların potansiyelini ortaya koymuştur. Çiftliklerde büyükbaşların izlenebilmesi çok önemli bir konu olmakla birlikte görüntü tabanlı tespit için temassız kameraların yanı sıra kulak etiketleri ve tasmalar gibi giyilebilir cihazların kullanılmasıyla sığır davranışlarının anlaşılmasına büyük katkı sağlamaktadır. Ayrıca, geniş popülasyonlara sahip çiftlik koşullarında birden fazla sığırın kameralarla takip edilmesi, ölçek farklılıkları ve rastgele hareketler nedeniyle önemli zorluklar ortaya çıkmaktadır. Bu problemleri çözebilmek için Han ve ark. (2023) yapmış olduğu bir çalışmada, video kullanarak çoklu sığır takibi için derin öğrenmeye dayalı bir çerçeve önermiştir. Önerilen bu algoritmaya göre, sığır tespiti için YOLOv5 dedektöründen yararlanılmıştır. Çalışma sonucunda, kullanılan yöntem veri ilişkilendirmede %84,49'luk bir doğruluk elde etmiştir. Bu durum hassas hayvancılık uygulamalarında karşılaşılan zorluklar göz önüne alındığında önemli bir gelişmeyi temsil etmektedir.

Yapay sinir ağlarının hayvanlarda genomik seleksiyon için ilk uygulaması, Okut ve ark. (2011) tarafından farelerde vücut kitle indeksini (VKİ) tahmin etmek için tam bağlantılı ANN'ler kullanılarak tanıtılmıştır (yani, bir giriş, bir gizli ve bir çıkış katmanına (üç katmana) sahip, beslemeli ileri bağlantılı bir YSA). Çalışmada, YSA'nın ilk katmanı, giriş SNP'leri içermektedir. İç katman gizlidir ve önceki katmandan alınan bilgiyi, dönüşümler dizisi olarak adaptif bir şekilde değiştirmektedir ve ardından gizli katmanın çıktısını (çıkış katmanına) giriş olarak geçirmektedir. O zamandan beri, karmaşık özelliklerin genomik seleksiyon için daha karmaşık YSA mimarileri önerilmiştir. Çiftlik hayvanlarında yapılan genomik tahmin nadir çalışmadan bir tanesi, Lee ve ark. (2023) tarafından sığırlarda gerçekleştirilmiştir. Genomik seleksiyon veya genomik tahmin, SNP'ler veya tam genom dizisi gibi gözlemlenen genomik bilgilerden karmaşık özellikleri tahmin etmeye yönelik genetik değeri tahmin etmek için değerli bir araçtır. Lee ve ark. (2023), derin öğrenme ağlarını ve genomik en iyi doğrusal tarafsız tahmin (GBLUP) çerçevesini birleştiren, deepGBLUP adı verilen yeni bir genomik tahmin algoritması geliştirmişlerdir. Önerilen deepGBLUP yöntemi geleneksel GBLUP ve Bayesian yöntemleriyle karşılaştırılmıştır. DeepGBLUP, Kore yerli sığır verileri ve simüle edilmiş veriler üzerinde yapılan kapsamlı değerlendirmeler sayesinde çeşitli özellikler, marker yoğunlukları, eğitim boyutları, kalıtsallıklar ve QTL etkileri karşısında sürekli olarak üstün performans elde etmiştir. Ayrıca, deepGBLUP'un



çeşitli kalıtım dereceleri ve niceliksel özellik lokusları (QTL) etkileri açısından simüle edilmiş veriler üzerinde önceki yöntemlere kıyasla daha iyi bir performans sergileyebileceğini göstermektedir.

## Sonuç

Bu derleme makalesi, çiftlik hayvanlarında derin öğrenme modellerinin kullanımını ele almış ve bu teknolojinin hayvancılık ve veterinerlik sektörlerindeki son gelişmelerini derleyerek genel bir bakış sunmuştur. İncelenen çalışmalar, yapay zekâ tabanlı sistemlerin hayvan refahını artırma, hastalıkların erken teşhisi ve çiftçilere etkili çiftlik yönetimi konusunda önemli faydalar sunduğunu göstermektedir. Derin öğrenme, yönetimin optimize edilmesiyle sadece verimliliği artırmakla kalmayıp, aynı zamanda ürün kalitesinin de artmasına olanak tanımaktadır. Dolayısıyla, tüketicilerin ürünlere olan güvenini artırma potansiyeline sahiptir. Öte yandan, derin öğrenme modellerinin yaygınlaştırılması ve başarıyla uygulanması konusunda; veri setlerinin derlenmesi, personel eğitimi için gereken süre ve yüksek üretim için derin öğrenme uzmanlarının varlığı gibi ele alınması gereken zorluklar mevcuttur. Diğer bir zorluk ise derin öğrenmeyle ilişkili yüksek hesaplama maliyetidir. Yüksek hesaplama maliyeti, kırsal bölgeler gibi sınırlı kaynaklara sahip alanlarda, bu teknolojilerin kullanımını kısıtlayan önemli bir engel olarak karşımıza çıkmaktadır. Bu durum, özellikle büyük veri kümeleri üzerinde çalışırken ve model karmaşıklığı arttıkça ortaya çıkmaktadır. Ek olarak, tarımsal veri setleri sıklıkla eksik veya bozuk veriler içermektedir. Bu durum, veri analitiği ve makine öğrenimi uygulamalarında önemli bir zorluk oluşturmaktadır. Eksik veya tamamlanmamış verilerin bulunması, model performansını olumsuz etkileyebilmekte ve doğru sonuçlar elde etmeyi zorlaştırabilmektedir. Dolayısıyla, tarım sektöründe kullanılan veri analizi ve yapay zekâ teknikleri, eksik veya bozuk verilerle etkili bir şekilde başa çıkabilecek yöntemleri içermelidir. Bu yöntemler, veri setlerinin kalitesini artırmaya ve doğru kararlar alınmasını sağlamaya yardımcı olabilecektir.

Makine öğrenmesi ve derin öğrenme gibi teknolojilerin hayvancılık sektöründe kullanımı, genel olarak sektördeki gelecek için umut vaat eden bir perspektif sunmaktadır. Bu teknolojilerin etkin bir şekilde kullanılması, çiftçilere ve endüstri uzmanlarına daha akıllı ve verimli çözümler sunarak tarımsal üretimde önemli bir dönüşümü mümkün kılacaktır. Ancak, bu teknolojilerin yaygınlaştırılması ve çiftliklerde uygulanması için daha fazla araştırmaya ve altyapıya ihtiyaç duyulmaktadır.

## Kaynaklar

- Aldridge, M. E., Fearon, J. E., Haynes, B. P., Miller, H. M., Sanford, K. Y., Scott, R. R., ... & Memili, E. (2018). Solutions for grand challenges in goat and Sheep Production. *Biotropia*, 26(1), 55-64. <https://doi.org/10.11598/btb.2019.26.1.944>.
- Alimi, M., Diwan, A. D., Erwin, W. M., Little, C. B., & Melrose, J. (2023). An update on animal models of intervertebral disc degeneration and low back pain: exploring the potential of artificial intelligence to improve research analysis and development of prospective therapeutics. *JOR Spine*, 6(1), e1230. <https://doi.org/10.1002/jsp2.1230>
- Alp, S., & Öz, E. (2019). Makine öğrenmesinde sınıflandırma yöntemleri ve R uygulamaları. *Nobel Akademik Yayıncılık*.
- Alves, T. S., Pinto, M. A., Ventura, P., Neves, C. J., Biron, D. G., Junior, A. C., ... & Rodrigues, P. J. (2020). Automatic detection and classification of honey bee comb cells using deep learning. *Computers and Electronics in Agriculture*, 170, 105244. <https://doi.org/10.1016/j.compag.2020.105244>
- Bao, J., & Xie, Q. (2022). Artificial intelligence in animal farming: A systematic literature review. *Journal of Cleaner Production*, 331, 129956. <https://doi.org/10.1016/j.jclepro.2021.129956>
- Barbedo, J. G. A., Koenigkan, L. V., Santos, T. T., & Santos, P. M. (2019). A study on the detection of cattle in UAV images using deep learning. *Sensors*, 19(24), 5436. <https://doi.org/10.3390/s19245436>
- Beausoleil, N. J., Blache, D., Stafford, K. J., Mellor, D. J., & Noble, A. D. (2012). Selection for temperament in sheep: domain-general and context-specific traits. *Applied Animal Behaviour Science*, 139(1-2), 74-85. <https://doi.org/10.1016/j.applanim.2012.02.020>
- Berkaya, S. K., Gunal, E. S., & Gunal, S. (2021). Deep learning-based classification models for beehive monitoring. *Ecological Informatics*, 64, 101353. <https://doi.org/10.1016/j.ecoinf.2021.101353>
- Bezen, R., Edan, Y., & Halachmi, I. (2020). Computer vision system for measuring individual cow feed intake using RGB-D camera and deep learning algorithms. *Computers and Electronics in Agriculture*, 172, 105345. <https://doi.org/10.1016/j.compag.2020.105345>
- Bondi, E., Oh, H., Xu, H., Fang, F., Dilkina, B., & Tambe, M. (2019). AMAS: Proceedings of the 18th International Conference on Autonomous Agents and MultiAgent Systems, Canada, 2336-2338.
- Cihan, P., Gökçe, E., Atakişi, O., Kırmızıgül, A. H., & Erdoğan, H. M. (2021). Prediction of immunoglobulin G in lambs with artificial intelligence methods. *Kafkas Üniversitesi Veteriner Fakültesi Dergisi*, 27(1), 21-27. <https://doi.org/10.9775/kvfd.2020.24642>
- Cowton, J., Kyriazakis, I., Plötz, T., & Bacardit, J. (2018). A combined deep learning gru-autoencoder for the early detection of respiratory disease in pigs using multiple environmental sensors. *Sensors*, 18(8), 2521. <https://doi.org/10.3390/s18082521>
- Çayroğlu, İ. (2015). İleri algoritma analizi - Yapay sinir ağlar. [http://www.ibrahimcayiroglu.com/Dokumanlar/IleriAlgoritmaAnalizi-5.Hafta-YapaySinirAglari.pdf](http://www.ibrahimcayiroglu.com/Dokumanlar/IleriAlgoritmaAnalizi/IleriAlgoritmaAnalizi-5.Hafta-YapaySinirAglari.pdf)
- da Silva, I. N., Spatti, D. H., Flauzino, R. A., Liboni, L. H. B., & Alves, S.F.R. (2016). Artificial Neural Networks: A Practical Course. *Springer*.
- Dac, H. H., Gonzalez Viejo, C., Lipovetzky, N., Tongson, E., Dunshea, F. R., & Fuentes, S. (2022). Livestock identification using deep learning for traceability. *Sensors*, 22(21), 8256. <https://doi.org/10.3390/s22218256>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep learning. *MIT press*.
- Gourisaria, M. K., Arora, A., Bilgaiyan, S., & Sahni, M. (2023). Chicken disease multiclass classification using deep learning. *Proceedings of International Conference on Information Technology and Applications*, 614, 225-238. <https://doi.org/10.1049/cmu2.12338>
- Guo, Y., Aggrey, S. E., Wang, P., Oladeinde, A., & Chai, L. (2022). Monitoring behaviors of broiler chickens at different ages with deep learning. *Animals*, 12(23), 3390. <https://doi.org/10.3390/ani12233390>
- Gültekin, N. & Doğan, A. (2023). Makine öğrenimi yöntemleriyle bazaltlarda tek eksenli Sıkışma Dayanımının Değerlendirilmesi ve Performanslarının Karşılaştırılması. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 11(2), 1059-1074. <https://doi.org/10.29130/dubited.1173624>



- Han, S., Fuentes, A., Yoon, S., Jeong, Y., Kim, H., & Park, D. S. (2023). Deep learning-based multi-cattle tracking in crowded livestock farming using video. *Computers and Electronics in Agriculture*, 212, 108044. <https://doi.org/10.1016/j.compag.2023.108044>
- Hodgkin, A. L. & Huxley, A. F. (1952). The dual effect of membrane potential on sodium conductance in the giant axon of *Loligo*. *The Journal of Physiology*, 116, 497-506. <https://doi.org/10.1113/jphysiol.1952.sp004719>
- Jiménez, D., Delerce, S., Dorado, H., Cock, J., Muñoz, L. A., Agamez, A., & Jarvis, A. (2019). A scalable scheme to implement data-driven agriculture for small-scale farmers. *Global Food Security*, 23, 256-266. <https://doi.org/10.1016/j.gfs.2019.08.004>
- Kaur J., & Gupta N. (2020) Bipolar sigmoid algorithm for designing constructive neural network. *International Journal on Emerging Technologies*, 11(2), 991-996.
- Khanikar, D., Phookan, A., & Gogoi, A. (2022, June 23). Artificial Neural Networks: An Introduction and Application in Animal Breeding and Production: A Review. *Agricultural Reviews*. <https://arccjournals.com/journal/agricultural-reviews/R-2421>
- Kongsilp, P., Taetragool, U., & Duangphakdee, O. (2024). Individual honey bee tracking in a beehive environment using deep learning and Kalman filter. *Scientific Reports*, 14(1), 1061. <https://doi.org/10.1038/s41598-023-44718-y>
- Krogh, A. (2008). What are artificial neural networks?. *Nature biotechnology*, 26(2), 195-197. <https://doi.org/10.1038/nbt1386>.
- Kröse B. & Smagt, P. V. D. (1996). An introduction to neural networks. *The University of Amsterdam*.
- Kubat, M. (2021). An Introduction to Machine Learning. *Springer*. <https://doi.org/10.1007/978-3-319-63913-0>
- Lasekan, A., Bakar, F. A., & Hashim, D. (2013). Potential of chicken by products as sources of useful biological resources. *Waste Management*, 33(3), 552-565. <https://doi.org/10.1016/j.wasman.2012.08.001>
- Lee, H. J., Lee, J. H., Gondro, C., Koh, Y. J., & Lee, S. H. (2023). deepGBLUP: joint deep learning networks and GBLUP framework for accurate genomic prediction of complex traits in Korean native cattle. *Genetics Selection Evolution*, 55(1), 56. <https://doi.org/10.1186/s12711-023-00825-y>
- Liu, H. W., Chen, C. H., Tsai, Y. C., Hsieh, K. W., & Lin, H. T. (2021). Identifying images of dead chickens with a chicken removal system integrated with a deep learning algorithm. *Sensors*, 21(11), 3579. <https://doi.org/10.3390/s21113579>
- Lösel, P. D., Monchanin, C., Lebrun, R., Jayme, A., Relle, J. J., Devaud, J. M., ... & Lihoreau, M. (2023). Natural variability in bee brain size and symmetry revealed by micro-CT imaging and deep learning. *PLoS Computational Biology*, 19(10), e1011529. <https://doi.org/10.1371/journal.pcbi.1011529>
- Mathison, B. A., Kohan, J. L., Walker, J. F., Smith, R. B., Ardon, O., & Couturier, M. R. (2020). Detection of intestinal protozoa in trichrome-stained stool specimens by use of a deep convolutional neural network. *Journal of Clinical Microbiology*, 58(6), 10-1128. <https://doi.org/10.1128/JCM.02053-19>
- Mishra, S., & Sharma, S. K. (2023). Advanced contribution of IoT in agricultural production for the development of smart livestock environments. *Internet of Things*, 22(4), 100724. <https://doi.org/10.1016/j.iot.2023.100724>
- Morris, S. T. (2017). Overview of sheep production systems. In D. Ferguson, C. Lee & A. Fisher (Eds.), *Advances in Sheep Welfare* (pp. 19-35). Woodhead Publishing.
- 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>
- Nayeri, S., Sargolzaei, M., & Tulpan, D. (2019). A review of traditional and machine learning methods applied to animal breeding. *Animal Health Research Reviews*, 20(1), 31-46. <https://doi.org/10.1017/S1466252319000148>
- 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>
- Okut, H., Gianola, D., Rosa, G. J. M. & Weigel, K. A. (2011). Prediction of body mass index in mice using dense molecular markers and a regularized neural network. *Genetics Research* 93(3),189-201. <http://dx.doi.org/10.1017/S0016672310000662>
- Oyibo, P., Jujjavarapu, S., Meulah, B., Agbana, T., Braakman, I., van Diepen, A., ... & Diehl, J. C. (2022). Schistoscope: an automated microscope with artificial intelligence for detection of *Schistosoma haematobium* eggs in resource-limited settings. *Micromachines*, 13(5), 643. <https://doi.org/10.3390/mi13050643>
- Öztemel, E. (2012). Yapay sinir ağları. *Papatya Yayıncılık*.
- Parrish, K. (2018). Deep learning vs. machine learning: What's the difference between the two. <https://www.digitaltrends.com/cool-tech/deep-learning-vs-machine-learning-explained/2/>
- Phythian, C. J., Michalopoulou, E., Jones, P. H., Winter, A. C., Clarkson, M. J., Stubbings, L. A., Grove-White, D., Cripps, P. J., & Duncan, J. S. (2011). Validating indicators of sheep welfare through a consensus of expert opinion. *Animal : an international journal of animal bioscience*, 5(6), 943-952. <https://doi.org/10.1017/S1751731110002594>
- Richert, W. (2013). Building machine learning systems with Python. *Packt Publishing*.
- Rojas-Downing, M.M., Nejadhashemi, A.P., Harrigan, T. & Woznicki, S.A. (2017). Climate change and livestock: Impacts, adaptation, and mitigation. *Elsevier*.
- Sağıroğlu, Ş., Beşdok E., & Erler, M. (2003). Mühendislikte yapay zekâ uygulamaları - yapay sinir ağları. *Ufuk Kitap Yayıncılık*.
- Strömbom, D., & King, A. J. (2018). Robot collection and transport of objects: A biomimetic process. *Frontiers in Robotics and AI*, 5, 48. <https://doi.org/10.3389/frobt.2018.00048>
- Sun, S., Wei, L., Chen, Z., Chai, Y., Wang, S., & Sun, R. (2024). Nondestructive estimation method of live chicken leg weight based on deep learning. *Poultry Science*, 103477. <https://doi.org/10.1016/j.psj.2024.103477>
- Terlouw, E. M. C., Arnould, C., Aupérin, B., Berri, C., Le Bihan-Duval, E., Deiss, V., ... & Mounier, L. (2008). Pre-slaughter conditions, animal stress and welfare: current status and possible future research. *Animal*, 2(10), 1501-1517. <https://doi.org/10.1017/S1751731108002723>
- Yavuz, S., & Deveci, M. (2012). İstatiksel normalizasyon tekniklerinin yapay sinir ağı performansına etkisi. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, (40), 167-187.
- Yaxley, K. J., Joiner, K. F., & Abbass, H. (2021). Drone approach parameters leading to lower stress sheep flocking and movement: sky shepherding. *Scientific reports*, 11(1), 7803. <https://doi.org/10.1038/s41598-021-87453-y>
- Voudiotis, G., Moraiti, A., & Kontogiannis, S. (2022). Deep learning beehive monitoring system for early detection of the Varroa mite. *Signals*, 3(3), 506-523. <https://doi.org/10.3390/signals3030030>
- Zingaro, M., Salvatori, V., Vielmi, L., & Boitani, L. (2018). Are the livestock guarding dogs where they are supposed to be?. *Applied Animal Behaviour Science*, 198, 89-94. <http://dx.doi.org/10.1016/j.applanim.2017.10.002>