



Yapay Zekâ Teknolojilerinin Hayvancılıkta Kullanımı

Application of Artificial Intelligence Technologies in Livestock Management

Niyazi Hayrullah TUVAY 0000-0002-7603-8721 Orhan ERMETİN* 0000-0002-3404-0452

Yozgat Bozok Üniversitesi, Ziraat Fakültesi, Zootekni Bölümü / Yozgat

ÖZET

Yapay zekâ teknolojisi sayesinde üretilen yazılımlar, çeşitli sensörler ve akıllı makineler birçok sektörde başarılı bir şekilde kullanılmaktadır. Yapay zekâ uygulamaları ile hayvancılık alanında sağlıklı kararlar verebilmek, doğru yorumlar yapabilmek ve çok daha fazla sayıda değişkeni daha kısa zamanda inceleyip sonuca varmak mümkün olabilmektedir. Bu teknolojiler, insan işgücünü ve insan kaynaklı hataları büyük ölçüde azaltarak verimlilik ve ürün kalitesinin iyileştirilmesine de yardımcı olmaktadır. Yapay zekâ teknolojileri, sağladığı avantaj ve kolaylıklarla hayvancılık alanında giderek yaygın bir şekilde kullanılmaya başlanmıştır. Hayvan yetiştiriciliğinde uygulamaları gittikçe artan yapay zekâ programları ile hayvanların duygusal durumları, beslenme alışkanlıkları, süt verimlerinin kontrolü ve sürü yönetimi gibi pek çok alanda insan müdahale ve hatası ortadan kaldırılmaktadır. Hayvanları tanımlamak için uygulanan küpe, işaret, etiket ve benzeri dış etmenleri de ortadan kaldırarak, hem iş yükünü ve maliyeti azaltmakta hem de hayvan refahına katkı sunmaktadır. Ayrıca biyogüvenlik, hastalık takibi ve kontrolü, hayvanların izlenmesi, çiftlik yönetimi, çiftlik hayvanlarında büyümenin kontrolü ve benzeri konularda kullanılmaktadır. Bu çalışmada hayvan yetiştiriciliğinde yapay zekâ uygulamaları hakkında bilgilere ve örneklere yer verilmiştir.

Anahtar Kelimeler: Yapay zekâ, hayvancılık, yapay sinir ağları, derin öğrenme.

ABSTRACT

Software, various sensors, and smart machines produced by artificial intelligence technology are used successfully in many sectors. With artificial intelligence applications, it is possible to make healthy decisions in the field of animal husbandry, to make correct interpretations, and to analyze many more variables in a shorter time and reach a conclusion. These technologies also help improve productivity and product quality by greatly reducing human labor and human error. Artificial intelligence technologies have been increasingly used in the field of animal husbandry with the advantages and conveniences it provides. With artificial intelligence programs, which are increasingly used in animal husbandry, human intervention and error are eliminated in many areas such as the emotional state of animals, nutritional habits, control of milk yields, and herd management. By eliminating external factors such as earrings, signs, tags, etc. which are applied to identify animals, these technologies not only reduce the workload and cost, but also contribute to animal welfare. They are also used in biosecurity, disease monitoring and control, animal monitoring, farm management, control of growth in farm animals, and similar issues. In this study, information and examples about artificial intelligence applications in animal husbandry are presented.

Keywords: Artificial intelligence, animal husbandry, artificial neural network, deep learning.

Atf: Tuvay, N.H., Ermetin, O. 2023. Yapay zekâ teknolojilerinin hayvancılıkta kullanımı. Hayvansal Üretim 64(1): 48-58. <https://doi.org/10.29185/hayuretim.1034328>

Citation: Tuvay, N.H., Ermetin, O. 2023. Application of artificial intelligence technologies in livestock management. Journal of Animal Production 64(1): 48-58. <https://doi.org/10.29185/hayuretim.1034328>

Geliş tarihi (Received): 08.12.2021

Kabul tarihi (Accepted): 07.04.2022

*Sorumlu yazar (correspondence): orhan.ermetin@bozok.edu.tr

GİRİŞ

Yapay zekâ, bir bilgisayarın ya da bilgisayar destekli bir makinenin, genellikle insana özgü nitelikler olan, çözüm yolu bulma, anlama, bir mana çıkartma,

genelleme ve geçmişteki deneyimlerinden öğrenme gibi yüksek mantıki süreçlere ilişkin görevleri yerine getirme yeteneği olarak belirtilmekte (Nabiyev, 2012; Öztürk ve Şahin, 2018) ve makineler tarafından

sergilenen insan zekâsı olarak kabul edilmektedir (Jones ve ark., 2018). İnsan gibi karar verebilen modeller üretebilme düşüncesi, insanlar için çok eskiye dayanan bir olgudur. Yapay zekânın tarihsel gelişimine kısaca bakacak olursak; George Boole, 1847'de mantıksal akıl yürütme için resmi bir dili tanımlayan ilk kişidir (Benko ve Lanyi, 2009). Yapay zekâ tarihindeki bir sonraki dönüm noktası, 1936'da Alan M. Turing'in Turing makinesini tanımlamasıdır. Warren McCulloch ve Walter Pitts 1943'te yapay nöron modelini ortaya atmış olup 1944'te J. Neumann ve O. Morgenstern ajanların tercihlerini belirlemek için eksiksiz ve resmi bir çerçeve sağlayan karar teorisini belirlemiştir. 1949'da Donald Hebb, öğrenme şansı sağlayan yapay nöronların bağlantıları için değer değiştiren bir kural sunmuş ve 1951'de Marvin Minsky ve Dean Edmonds ilk sinir bilgisayarını yapmıştır (Benko ve Lanyi, 2009). Yapay zekâ terimi ve tanımı ise ilk olarak 1955 yılında John McCarthy tarafından ortaya atılmıştır. John McCarthy, yapay zekâyı; "akıllı makineler yapma bilimi ve mühendisliği" olarak tanımlamıştır (Hamet ve Tremblay, 2017).

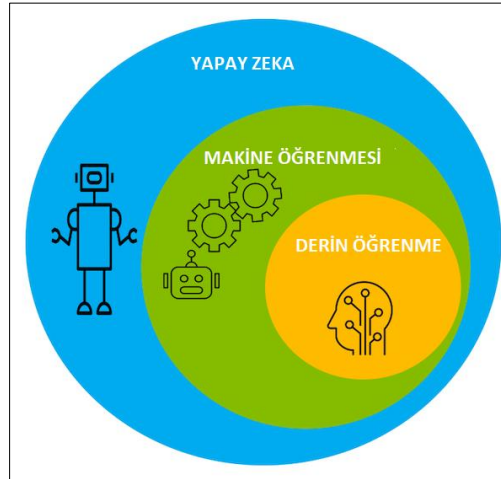
Yapay zekâ, en genel tanımıyla en az insan müdahalesi ile akıllı davranışı örneklemek için bir dizi bilgisayar programının kullanımını ifade eden genel bir terimdir. Yapay zekânın, robotların icadı ile başladığı genel kabul görmektedir. Yapay zekâ, insan beyninin çalışma ve düşünebilme yeteneğinden yola çıkılarak oluşturulmuş bir bilgi işlem teknolojisidir. Öğrenme özelliği sayesinde geleneksel teknikler için çok karmaşık kalan problemlere çözüm sağlayabilmekte ve bilinen örnekleri kullanarak daha önce karşılaşılmamış durumlarda genelleme yapabilmektedir. Sadece sayısal bilgilerle çalışan, bilgiyi saklama, örnekleri kullanarak öğrenme ve görülmemiş örnekler hakkında bilgi üretebilme, sınıflandırma ve şekil tamamlama gibi özelliklere sahip olan yapay zekâ teknolojileri günlük hayatımızda finansal konularda, tarımda, mühendislikte, tıp biliminde, üretim ve uygulamalarda arıza tespit ve analizine kadar birçok alanda uygulanabilmektedir (Ağyar, 2015).

Yapay zekâ, derin öğrenme, yapay sinir ağları ve otomasyon teknolojilerinin yaygınlaşmasıyla birlikte, bu modern teknolojilerin geleneksel hayvancılıkta uygulanabilirliği son yıllarda gündeme gelmeye başlamıştır. Bu teknolojilerin kullanımı, insan işgücünü büyük ölçüde azaltacak, modern üretim verimliliğini artıracak ve ürün kalitesinin iyileştirilmesine de katkıda bulunacaktır (Neethirajan, 2021). Yapay zekâ çıktıları ile karşılaşılabilecek olumsuzluklara karşı önceden tedbirler alınabilecek; işletme içi tasarruf sağlanacak, hayvanlara müdahaleler en aza indirilerek doğal davranışları sergilemesi sağlanacak ve işletme kazancı artırılmış olacaktır. Bu çalışmada özellikle son yıllardaki

gelişmeler göz önünde bulundurularak, hayvansal üretimde başarıyla uygulanmakta olan yapay zekâ uygulamaları hakkında bilgi verilmeye çalışılmıştır.

YAPAY ZEKÂNIN ALT DALLARI

Madan ve Madhavan (2020) Şekil 1'de görüldüğü gibi yapay zekâ, makine öğrenmesi ve derin öğrenme ilişkisini sunmuştur. Yapay zekâ teknolojilerinin alt dalları makine öğrenimi, derin öğrenme, yapay sinir ağları, bilgisayar görüntüsü, robotlar ve doğal dil işleme şeklinde sıralanabilir.



Şekil 1. Yapay zekâ, makine öğrenmesi ve derin öğrenme ilişkisi (Madan ve Madhavan, 2020)

Figure 1. The relationship between artificial intelligence, machine learning and deep learning

Makine Öğrenimi (Machine Learning – ML)

Bilgisayarların açıkça programlanmadan, örnekler ve öğretilen verilerden yola çıkarak bilişsel işlemler yapmasına olanak veren algoritmalar olarak tanımlanabilir. Verdiği sonuç öğrenme sistemlerine girilen verilere bağlıdır. Makine öğrenimi, çevredeki ortamdan öğrenerek insan zekâsını taklit etmek için tasarlanmış, gelişen bir hesaplama algoritmasıdır (Zhang, 2020). Genellikle örnekler kullanılarak olayların girdi ve çıktıları arasındaki ilişkiler öğrenilir. Makine öğrenimine dayalı teknikler, örüntü tanıma, bilgisayarla görme, uzay aracı mühendisliği, finans, eğlence ve hesaplamalı biyolojiden biyomedikal ve tıbbi uygulamalara kadar çeşitli alanlarda başarıyla uygulanmıştır (El Naqa ve Murphy, 2015). Denetimli ve denetimsiz öğrenme sistemleri vardır. Denetimli öğrenme, sistemi öğrenme ve doğru sonucu vermede kullanılır iken denetimsiz öğrenme sisteme çok sayıda örnek sunarak cevap vermeden çalışır. Tıbbi riskleri saptamada kullanılan sistemler denetimli öğrenmeye örnek olarak verilebilir. Denetimsiz öğrenmeye ise müşteri gruplarını sınıflandırma ve korelasyon kurma örnek gösterilebilir. Makine öğrenimi ve yapay zekâ

genellikle bir arada değerlendirilir. Kimi durumlarda birbirinin yerine kullanılır ancak aynı anlama gelmezler. Tüm makine öğrenimi çözümleri yapay zekâ iken tüm yapay zekâ çözümlerinin makine öğrenimi olmaması önemli bir ayrımdır.

Derin Öğrenme (Deep Learning – DL)

Derin öğrenme, veri temsillerini öğrenmeye dayalı bir tür makine öğrenimi yöntemidir (Giger, 2020). Verilen bir veri kümesi ile çıktıları tahmin edecek yapay zekâyı eğitmeye olanak sağlar. Yapay zekâyı eğitmek için hem denetimli hem de denetimsiz öğrenme kullanılabilir. İnsanların tecrübelerinden öğrendiklerine benzer olarak, derin öğrenme algoritması, sonucu iyileştirmek adına her defasında biraz değişiklik yaparak daha iyi bir iş çıkarmaktadır. Derin öğrenme, düşünce gerektiren herhangi bir problem hakkındaki çözümü gerçekleştirebilir. Görüntü analizi, ses analizi, robotik/otonom araçlar, gen analizleri, kanser teşhisleri ve sanal gerçeklik gibi birçok alanda kullanılmaktadır. Günümüzde karmaşık görevlerde kullanılan derin öğrenme modelleri eğiten algoritmalar (Inik ve Ülker, 2017). Derin öğrenmenin çok yaygın bir alanda kullanılmasının en büyük sebebi, problemlerin çözümünde elde ettiği kolaylık ve yüksek doğruluktur (O'Mahony ve ark., 2019). Son birkaç yılda, Derin Sinir Ağları – DSA (Deep Neural Network – DNN) yetenekleri, görüntüleri tanıma ve yorumlamada insanların yerini aldı. Bu DSA'lar, evrişim filtreleri kullanarak bir giriş görüntüsünden özellikleri otomatik olarak çıkarmak için Evrişimli Sinir Ağları – ESA (Convolutional Neural Networks - CNN) kullanılmaktadır (He ve ark., 2017).

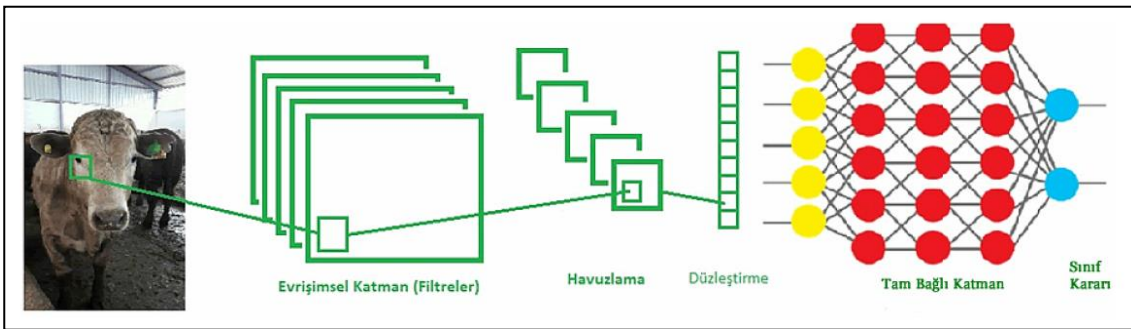
Yapay Sinir Ağları (Artificial Neural Networks - ANNs)

Yapay sinir ağları (YSA), yapay zekânın araştırma alanı içinde makine öğreniminin bir alt alanıdır (Zhang,

2018). YSA, makine öğrenimi için kullanılan ve insanların yaptığı gibi birçok nitel ve nicel sorunun doğasını yorumlayabilen bir grup algoritmadır. İnsan beyninin fonksiyonel özelliklerine benzer şekilde, öğrenme, ilişkilendirme, sınıflandırma, genelleme, özellik belirleme, optimizasyon gibi konularda başarılı bir şekilde uygulanmaktadır. YSA, örneklerden elde ettikleri bilgiler ile kendi deneyimlerini oluşturur ve daha sonra benzer konularda benzer kararları verirler. Çok sayıda algılayıcı sensörlerin verilerini sentezleyerek bir olguya dönüştürmektedir. İnsan beynindeki biyolojik sinir ağlarının yapısından esinlenilmiştir (Hertz ve ark., 1991). YSA'lar, bilginin iletilmesi, işlenmesi ve depolanması olmak üzere üç temel bileşenden oluşmakta olup, birçok karmaşık problemi çözmeye kapsamlı olarak kullanılan yeni bir hesaplama/bilgi işleme aracıdır (Hornik, 1991).

van Gerven ve Bohte (2017), örneklerden öğrenebilen gelişmiş bilgisayarlı öğrenme algoritmaları olarak tanımlamıştır. YSA'ların çekiciliği, esas olarak doğrusal olmama, yüksek paralellik, hata ve gürültü toleransı ile öğrenme ve genelleme yetenekleri ile hızlı bilgi işleme özelliklerinden kaynaklanmaktadır (Basheer ve Hajmeer, 2000).

Derin öğrenme için kullanılan modellerin en popüler olanlarından biri ESA'dır. ESA bilgisayarlı görüş uygulamalarında kullanılmak üzere geliştirilmiş çok katmanlı yapay sinir ağlarının özel bir modelidir. Biyolojik süreçlerden esinlenilmiş, özellik çıkarma ve sınıflandırmayı birleştirerek, doğrudan görüntünün piksellerinden (veya diğer sinyallerden) kalıpları tanımak üzere tasarlanmış ileri beslemeli yapay sinir ağlarıdır (Andrew ve ark., 2013; Dandil ve ark., 2019). Şekil 2'de ESA çalışma şablonu sunulmuştur.



Şekil 2. Evrişimli Sinir Ağları (ESA) genel mimarisi (Dandil ve ark., 2019)

Figure 2. General structure of Convolutional Neural Networks (CNN)

Bilgisayar Görüntüsü (Computer Vision – CV)

Bilgisayarla görme, bilgisayarların ve sistemlerin dijital görüntülerden, videolardan ve diğer görsel girdilerden anlamlı bilgiler türetmesini ve bu bilgilere dayalı olarak

eylemde bulunmasını veya önerilerde bulunmasını sağlayan bir yapay zekâ alanıdır. Bu teknoloji, ileri düzey görüntü işlemek, hedefleri belirlemek, izlemek ve ölçmek amacıyla insan gözü yerine bir kamera ve

bilgisayar kullanır. Bilgisayarlı görü çok fazla veriye ihtiyaç duyar. Ayrımları ayırt edene ve nihayetinde görüntüleri tanıyana kadar veri analizlerini tekrar tekrar çalıştırır. Örneğin, bir bilgisayarı otomobil lastiklerini tanıyacak şekilde eğitmek için çok sayıda lastik resmi ve lastikle ilgili öğelerle beslenmesi gerekir. Bunu yapabilmesi için derin öğrenme ve ESA algoritmaları kullanılır. Benzer teknolojilerin ve bilgisayar görüntüsünün gelişmesiyle birlikte bu yeni teknolojilerin tarım otomasyonu alanında da kullanılmaya başlanılmış olması tarımın gelişimine katkı sağlamıştır (Ma ve ark., 2020).

Robotlar

Robot, ortamdaki topladığı verileri dünyası hakkında sahip olduğu bilgiyle sentezleyerek, anlamlı ve amaçlarına yönelik bir şekilde hareket edebilen ve bunu güvenli bir biçimde yapabilen bir makinedir (Mataric, 2007). Robotun tek ve basit bir tanımı bulunmadığı gibi her makine de robot değildir. Robotlar sensörler aracılığıyla algılar, veri toplar, kontrolünü sağlayarak karar verir ve hareketi gerçekleştirir.

Robot terimi, ilk olarak Çek oyun yazarı Karel Capek tarafından 1921 yılında yazılan "Rossum'un Evrensel Robotları" (Rossum's Universal Robots R.U.R) oyunuyla ortaya çıkmıştır (Mataric, 2007). Çekçe "hizmet eden, zorla çalıştırma olarak kullanılan biyosentetik makineler" anlamına gelen "robota" kelimesinden türemiştir (Hamet ve Tremblay, 2017).

Doğal Dil İşleme (Natural Language Processing–NLP)

Doğal dil işleme, yazılı metinleri analiz etme (text processing) ve konuşma tanıma (speech recognition) olarak ikiye ayrılır. Doğal dil işleme, hem bir dizi teoriye hem de bir dizi teknolojiye dayanan metni analiz etmeye yönelik bilgisayarlı bir yaklaşımdır. Doğal dil işleme, bir dizi görev veya uygulama için insan benzeri dil işlemeyi başarmak amacıyla bir veya daha fazla dilsel analiz düzeyinde doğal olarak oluşan metinleri analiz etmek ve temsil etmek için teorik olarak motive edilmiş bir dizi hesaplama tekniğidir (Liddy, 2001). Bilgisayarların insanların dillerini anlaması, onlarla iletişime geçmeleri için doğal dil işleme bilimi kullanmaları gerekmektedir. Kısacası, bilgisayarların doğal dilleri işleme sürecidir (Preece ve Rombach, 1994).

Otomatik Konuşma Tanıma (Automatic Speech Recognition) veya Bilgisayarlı Konuşma Tanıma (Computer Speech Recognition) veya Sesten Yazıya (Speech to Text) olarak da bilinen "Konuşma Tanıma", bir bilgisayar programının, insan sesini işleyerek yazıya dönüştürme yeteneğidir. Başka bir ifade ile ses sinyallerinin örneklenerek yapay sinir ağları, makine öğrenmesi gibi metotlarla anlamlı hale getirilmesidir.

Ses Tanıma (Voice Recognition) ile çok karıştırılır. Konuşma tanıma, konuşmanın sözlü biçimden metne çevrilmesine odaklanırken ses tanıma ise sadece sesin sahibini tanımayı amaçlamaktadır.

HAYVANCILIKTA YAPAY ZEKÂ TEKNOLOJİLERİNİN KULLANIMI

Gelişen teknoloji ile son yıllarda yapay zekâ teknikleri, hayvancılık işletmelerinde günlük işlerin düzenlenmesinde, kolaylaştırılmasında veya iyileştirme bekleyen sorunlara alternatif çözümler getirilmesinde önemli bir araç haline gelmiştir. Geliştirilen algoritma ve yazılımlar ile hayvancılıkla ilgili birçok konuda araştırmacılar tarafından çok sayıda çalışma yapılmış ve yapılmaya devam edilmektedir (Terzi ve ark., 2019).

Hayvan davranışları ve hayvan refahının iyileştirilmesi, çiftlik hayvanlarında besleme, büyüme, verim (üretim) ve gelirler üzerinde doğrudan etkilidir. Hayvanların davranış kalıplarını bilmek, streslerini en aza indirecek yönetim sistemlerinin ve ekipmanlarının geliştirilmesine imkân sağlamaktadır. Bu davranış kalıplarına uygun yetiştirilen veya otlatılan hayvanlarda stres en aza indirilmiş olmaktadır. Hayvanın doğumundan ölümüne kadar her dönemde önemli olan davranışlarında stresin en aza indirilmesi, hayvanın sadece yaşam kalitesini değil, verimliliğini de artırmaktadır (Ermetin ve Mülâyim, 2021). Hayvan bilimi içerisinde bugüne değin yapılan çalışmalar göstermiştir ki ne tek başına çevreyi ne de tek başına hayvanın genetik yapısını "yetiştiricinin arzuları doğrultusunda" optimize etmek mümkün olmuştur. Dolayısıyla optimizasyon bütüncül bir yaklaşımı gerektirir (Ermetin ve Mülâyim, 2021). Bu alanda yapay zekâ ile geliştirilen teknolojik ürünleri kullanarak optimizasyonun daha kolay sağlanacağı düşünülmektedir.


Chen ve ark. (2008) tarafından Çin'de yapılan çalışmada, süt sığırları gübresindeki besin maddesi miktarını belirlemek amacıyla çoklu lineer regresyon, polinom regresyonu ve yapay sinir ağlarının kullanılabilirliği araştırılmış ve yapay sinir ağları modelinin sığır gübresindeki besin madde içeriğini tahmin etmek için diğer iki modele göre daha uygun bir araç olduğu belirlenmiştir.

Elektronik burunlar, düşük işletme maliyeti, tutarlı ve objektif okumaları göz önüne alındığında gelişmeye açık bir konudur. Elektronik burun, bir dizi elektronik gaz sensörü ve bir sinyal işleme sisteminden oluşan ve basit veya karmaşık kokuları tanıyabilen bir alettir. Elektronik burun teknolojisinin, gıda endüstrisinde, tıpta ve çevresel izlemede yararlı bir araç olduğu kanıtlanmıştır ve uygulamalarda kullanılmaktadır (Gardner ve Bartlett, 1999). Ancak, tarımsal çevre izleme için elektronik burun kullanmak için çok az

çalışma yapılmıştır (Qu ve ark. 2001; Powers ve Bastyr, 2004). Henüz çiftlik hayvanları ve kümes hayvanlarının kokularını algılamak için ticari olarak yaygın şekilde kullanılabilen bir elektronik burun geliştirilmemiştir. Yapay zekâ teknolojilerinin gelişmesiyle Pan ve Yang (2007), besi ve kümes hayvanı çiftliklerindeki istenmeyen kokuları ölçmek ve analiz etmek için elektronik burun sistemi (sensörler) ve yapay zekâ teknolojisi yardımıyla koku kaynağı, etken maddesi ve zararlılık derecesini ölçmüşlerdir. Yapay zekâ teknolojisini sensörlere adapte ederek "akıllı elektronik burun" adını verdikleri sistemle özellikle kapalı şartlarda üretim yapan işletmelere koku yönetimi konusunda son derece faydalı olunacağını belirtmişlerdir (Pan ve Yang, 2007).

Borchers ve ark. (2017) tarafından yapılan çalışmada, süt sığırlarında doğum öncesi davranışları ölçerek, yapay zekâ teknolojisi yardımıyla buzağılama zamanı tahmin edilmiştir. Araştırmacılar iki yıl boyunca 20 baş tek doğum ve 33 baş çok doğum yapmış Holstein süt sığırında yatma süresi, ayakta durma süresi, ayakta duruştan yatışa geçiş sayısı, adım sayıları ve toplam hareket miktarları gibi verileri sensörler vasıtasıyla 15'er dakikalık aralıklarla kayıt altına almışlardır. Verilerin makine öğrenimi ile değerlendirilmesiyle doğum zamanlarını %100 duyarlılıkla ve %80,4 özgüllük ile buzağılamadan önceki 8 saatte tespit etmişlerdir. Araştırmacılar çalışmanın ticari olarak değerlendirilme potansiyeli olduğunu ve değerlendirildiği zaman hayvan refahı için önemli fayda sağlayacağını belirtmişlerdir.

Fuentes ve ark. (2020) Şekil 3'de sunulan biçimde çevre sıcaklığı parametreleriyle ısı stresi ve süt verimi etkilerini incelemiş, makine öğrenimi modelleriyle çevre sıcaklığı arttıkça konsantrasyon miktarı ile içeriği değiştirilerek ve su püskürtürerek serinletme sistemlerinin devreye girmesini sağlamışlardır. Fuentes ve ark. (2021) tarafından yürütülen başka bir çalışmada ise, robotik sağım kullanan bir işletmedeki süt sığırlarının süt üretimi ve kalitesini tahmin etmek için çeşitli özellikteki kameraları kullanarak kalp atış hızı, solunum hızı, vücut ve göz sıcaklığının etkisini makine öğrenimi modellemesi ile tahmin etmişlerdir. Elde edilen girdileri kullanan bir yapay sinir ağı ile günlük süt verimi, laktasyon süt verimi ve süt bileşenlerini tahmin etmede yüksek doğruluk ($R = 0.96$) elde etmişlerdir. Bu modelin, hayvan refahı ve biyotik/abiyotik stresi modellemek için de kullanılabilen göz sıcaklığı da dahil olmak üzere önerilen tüm hedefleri elde etmek için uygun kamera sistemleri kullanılarak kolayca uygulanabileceğini belirtmişlerdir.



Şekil 3. Spesifik inek veri girişi ve makine öğrenmesi için otomatik meteoroloji verileri ve radyo frekans tanımlama (RFID) üzerine kurulu yapay zekâ uygulaması (Fuentes ve ark., 2020)

Figure 3. Artificial intelligence application built on automated meteorological data and radio frequency identification (RFID) for specific cow data entry and machine learning


Grzesiak ve ark. (2006), süt ineklerinde süt verim tahminlerini yapay sinir ağları ve klasik metodlarla karşılaştırmış olup yapay sinir ağlarının kullanımının klasik regresyon modellerinden daha pratik olduğunu belirtmiştir. Süt sığırlarında süt verimi ve laktasyon süresi tahmini konusunda benzer çalışmalar yapan Görgülü (2012) ve Takma ve ark. (2012) yapay sinir ağlarının çoklu doğrusal regresyon analizine göre daha yüksek bir öngörüye sahip olduğunu ve daha az hataya sahip sonuçlar verdiğini belirtmişlerdir. Çetin ve Mikail (2016) süt sığırlarında verilerin toplanması, analiz edilmesi, işlenmesi ve depolanması gibi işlemler için kullanılan farklı veri madenciliği metodlarının olduğunu ama en kolay ve etkili uygulamanın yapay sinir ağları ile elde edildiğini bildirmiştir. Memmedova (2012), otomatik sağım sistemi kullanılan bir işletmede subklinik mastitisin tespitinde yapay sinir ağlarının kullanımında hassaslık %82, belirlilik %74, hatanın ise %60 bulunduğunu bildirmiştir.

Hayvanların düzenli olarak ağırlıklarını ölçmek yerine vücut bölümlerinin ölçümlerinin ağırlıklarıyla ilişkilendirildiği birçok araştırma yapılmıştır (Reis ve ark. 2008, Bretschneider ve ark. 2014, Franco ve ark. 2017). Buna ilave olarak, bilgisayar görüntüsü aracılığıyla görüntü analizine dayalı uygulamalar da geliştirilmiştir (Barbedo ve ark. 2018). Gjergji ve ark. (2020) ise yapay zekâ teknolojilerini hayvanların ağırlık değişimlerinin hesaplanmasında kullanmış olup sığır vücut ağırlığını tahmin etmek için ESA ve tekrarlayan dikkat modelleri üzerinde çalışmışlar ve ESA ile elde edilen bulguların en iyi sonuçları verdiğini belirtmişlerdir. Araştırmacılar hayvanların ağırlıklarını düzenli olarak ölçebilmek amacıyla hayvanların geçiş yolları, suluk ve yemliklerine tartı hücreleri koymayı gerektiren ve ayrıca hayvanların mutlaka bir tartım sistemi tarafından tartılması için bakıcılar tarafından

yönlendirilmesinin zorunlu olduğu sistemlerin aksine, ESA programlarının sadece görüntüyü kullandığını, hayvan refahı ve iş gücü kullanımı bakımından oldukça faydalı olduğunu belirtmişlerdir.

Avustralya ve Yeni Zelanda gibi geniş meralarda otlayan hayvanları tespit ederek ayırt etmek veya saymak oldukça güç olmaktadır. Akıllı kulak küpeleri, kamera kapanları ve kızılötesi termal görüntüleme gibi mevcut zemin tabanlı izleme teknikleri, geniş coğrafi kapsamda hayvanların tanımlanıp izlenebilmesi hakkında net bilgi vermemektedir (Norouzzadeh ve ark. 2018). Bu amaçla havadan görüntü alabilen dron veya benzer araçlardan yararlanılmaktadır (Barbedo ve Koenigkan, 2018). Son yıllarda Daha Hızlı Bölgesel-ESA (Faster R-CNN) ve Maske Bölgesel-ESA (Mask R-CNN) gibi ağların gelişmesiyle birlikte daha yüksek doğruluk, hassasiyet ve daha hızlı işlem kapasitesiyle çok sayıda görüntüden nesne algılama ve sınıflandırmasında yararlanılacağı belirtilmektedir (He ve ark., 2017; Ren ve ark., 2017). Xu ve ark. (2020) yaptıkları çalışmada geniş alanlarda yayılan sığırların tespiti ve tanımı için uzaktan kumandalı insansız mini helikopterlerle alınan hayvan görüntülerini Mask R-CNN makine öğrenimi

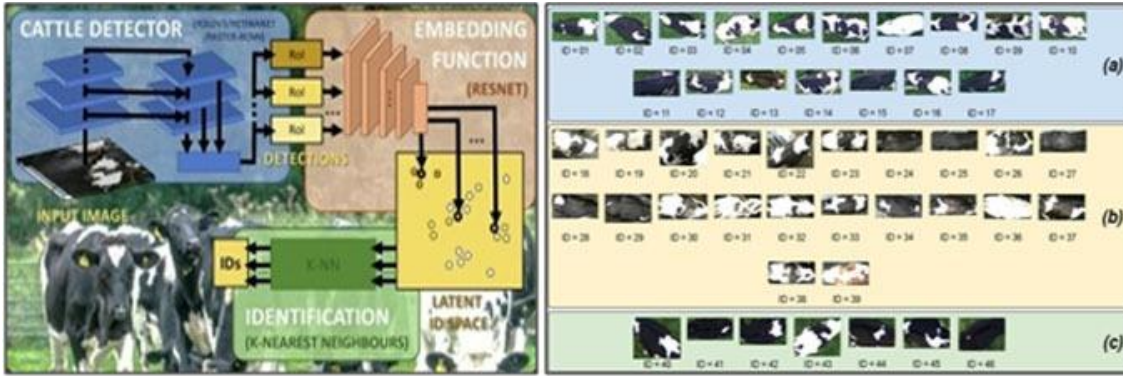
sayesinde algoritmalar kurarak daha kolay ve %94 başarı ile uygulamışlardır (Şekil 4).



Şekil 4. Meradaki ineklerin Mask R-CNN ile tespit edilmesi (Xu ve ark., 2020)

Figure 4. Detection of cows in the pasture with Mask R-CNN

Andrew ve ark. (2021) yaptıkları çalışmada Holstein-Friesian sığırlarını görsel olarak tanımlayarak renk skalasına göre ayırt etmeyi başarmışlardır (Şekil 5).




Şekil 5. Derin öğrenme yoluyla Holstein-Friesian sığırlarının görsel olarak bireysel tanımlanması (Andrew ve ark., 2021)

Figure 5. Visual individual identification of Holstein-Friesian cattle through deep learning

Hayvanları tanımlamada kullanılan boya, işaret, kulak etiketleri, boyun ve ayağa takılan radyo frekanslı çipler veya vücutlarına yerleştirilen transponderler ve sensörlerin zaman zaman kullanım zorlukları, hayvan sağlığına zararları ve müdahalelerle değiştirilebileceğinden yola çıkarak yeni tanımlama metotları geliştirilmiştir (Kumar ve ark., 2016; Kumar ve Singh, 2017). Çeşitli araştırmacılar sığırlarda burun yapısının insanların parmak izi gibi farklı olduğunu ve hayvanları tanımlamada kullanılabileceğini belirtmişlerdir (Barry ve ark., 2007; Awad ve ark., 2013). Sığırları bireysel olarak tanımlamak için Kumar ve ark. (2018) sığırların burun ucu görüntü desenlerini kullanarak derin öğrenme

yöntemleri ile analizlerini yapmış ve sığırları %99.89 doğrulukta tanımlamayı başarmışlardır (Şekil 6).

Hayvanların seslerinin, hayvanın yaşı, cinsiyeti, üreme durumu, ağrı, kızgınlık, buzağıdan ayrılma, açlık veya susuzluk gibi olağanüstü durumları hakkında bilgi içerdiği bilinmektedir (Ikeda ve Ishii, 2008). Jung ve ark. (2021) yaptıkları bir çalışmada, sığırları tanımlamak için sığırların seslerini kullanmışlardır. Geliştirilen model, bir yerinde izleme sisteminden sensörler aracılığıyla elde edilen sığır ses verilerine uygulanmış ve ses filtrelemesinden sonra ESA teknolojisi kullanarak %81,96 nihai doğruluk elde etmişlerdir. Araştırmacılar, çiftlik sahiplerinin hayvanlarını izleye-



Şekil 6. Burun deseni görüntüsü ile sığırların tanınması amacıyla derin öğrenme kullanımı (Kumar ve ark., 2018)

Figure 6. Use of deep learning to recognize cattle with nose pattern image

bilmesi için ilgili model bir web platformuna yüklenerek hayvanların tanımlama ve refahına katkı sağlayacağını belirtmişlerdir (Jung ve ark., 2021).

Ma ve ark. (2020) tarafından yapılan çalışmada, koyunların farklı yetiştirme koşulları altında üreme zamanlarının tespiti için Faster R-CNN sinir ağı modeline dayalı Soft-NMS algoritması geliştirilmiştir. Araştırmacılar geliştirdikleri bu model ile %95,32 doğrulukla kızgınlık tespitini yaparak koyunlarda üreme ve koyun davranışı araştırmaları için etkili bir veri temeli sağlanabileceğini bildirmişlerdir.

Çiftlik hayvanlarının davranışlarının araştırılmasında duygular, belirleyici ve bilgilendirici bir rol oynamaktadır. Çiftlik hayvanlarının yüzlerinin,

duyguları ifade etmek için faydalanılabilecek en zengin kanallardan biri olabileceğini belirten Neethirajan (2021), Python tabanlı algoritmaları kullanarak ineklerin ve domuzların yüz özelliklerini, görünüm, kulak duruşları, göz ve beyaz bölgelerini analiz ederek zihinsel/duygusal durumları ile ilişki kurmuştur (Şekil 7). Araştırmacı, YoloV3 ve Faster YoloV4 tabanlı yüz algılama platformuna dayalı gerçek zamanlı bir duyu tanıma sistemi ile birlikte ESA kullanarak hayvanların 13 yüz hareketini ve 9 duygusal durumunu saldırgan, sakin veya nötr olarak sınıflandırmıştır. Çalışmada, teknoloji geliştikçe benzer araştırmalar ile hayvan refahı ve hayvan-insan etkileşimlerini iyileştirmek için potansiyellerin olacağı belirtilmektedir.



Şekil 7. Değişen duyguları ifade eden ineklerin yüz özellikleri (Neethirajan, 2021).

Figure 7. Facial features of cows expressing changing emotions

Cavero ve ark. (2008) 373 süt ineği üzerinde yaptıkları çalışmada, kontrol grafiği ve yapay sinir ağıları kullanarak %99,6 doğrulukla kızgınlığı tespit etmişlerdir. Brunassi ve ark. (2010) çevresel sıcaklık, hareketlilik sapmaları, progesteron salınımı ve kızgınlık takvimini veri olarak Bulanık Mantık modelinde

kullanıp süt ineklerinde kızgınlık tahmini yapmışlar ve %84,2'lik doğruluk elde etmişlerdir. Memmedova ve Keskin (2011) önce inekleri hareket durumlarına göre "az hareketli", "orta hareketli" ve "çok hareketli" olarak sınıflandırmışlar sonra Bulanık Mantık modelini oluşturmuşlar ve kızgınlık tespit oranını %98 olarak

bildirmişlerdir. Yıldız (2016), yapay sinir ağları kullanarak süt sığırlarında kızgınlık belirleme çalışmasında sadece hayvanların hareketliliklerinin tespiti yanında iklim etmenlerinin de (sıcaklık, nem vb.) ele alınmasının daha doğru sonuçlar vereceğini bildirmiştir.

Koyun yetiştiriciliğinde özellikle ayakta olan yaralanmalar ve mastitis gibi hastalıklar önemli bir ağrı kaynağıdır ve hayvan refahı ve verimliliğini olumsuz etkiler (Kaler ve ark., 2010). Koyun sürülerinde hastalıklı hayvanları tespit etmek oldukça güçtür. Hastalığın yayılmasını tespit etmek ve kontrol etmek için entegre bir bütün-sistem yaklaşımına ihtiyaç vardır. Bu durum sürünün refahı ve genel verimliliği üzerine oldukça etkilidir. Hastalık veya rahatsızlık durumunu tespit etmek için bu yeni teknolojiden yararlanma ihtiyacı olduğu vurgulanmıştır (Roberts ve ark., 2014). Koyun Ağrısı Yüz İfadesi Ölçeği (SPFES) Mahmoud ve ark. (2018) tarafından geliştirilerek üreticilere ve veterinerlere koyunlardaki ağrıyı tanımlarına ve değerlendirmelerine yardımcı olacak güvenilir ve etkili bir araç olarak sunulmuştur. Yüz ifadesi, duygusal bir uyarana karşı "eylem birimleri" olarak bilinen yüzde veya kas gruplarında meydana gelen değişikliklerin ölçümüdür ve muhtemelen bir hayvanın yaşadığı ağrıya istemsiz bir tepkidir (Langford ve ark., 2010). Yüz ifadesi, ağrının yoğunluğunun dürüst bir işareti olarak kabul edildiğinden (Poole ve Craig, 1992), bireysel yüz ifadelerinin öğrenilmesine ve ardından olası hastalık varlığını düşündüren ifadelerin ne zaman değiştiğinin tespit edilmesine olanak tanıyan otomatik bir sistem, tarama sürecini iyileştirmek için hayati önem taşımaktadır. İyi entegre edilmiş bir otomatik sistem, değerlendirmenin herhangi bir özneliliğini ortadan kaldırarak ağrı tahmininin tutarlılığını sağlamaktadır. Tedaviden önce ve sonra bu değişiklikleri değerlendirmek için bir gözlemcinin sürekli varlığını gerektirmeyeceğinden bakımdaki verimliliği artıracaktır (Porter ve ark., 2012). Hewitt ve Mahmud (2019) koyunların yüz ifadelerini derin öğrenmeye dayalı bir makine öğrenimi teknolojisiyle tespit etmek amacıyla koyun yüzünde 25 farklı referans noktası şeması belirlemiş ve bir model geliştirmiştir. Böylelikle, özellikle yüzün ön kısmından hem koyunların ayırt edilebileceğini hem de ağrı puanlarının tespit edilebileceğini belirtmişlerdir. McLennan ve Mahmoud (2019) ise koyunlarda özellikle acı ve ağrı duygularının yüzlerinden belirlenebilmesi için derin öğrenme yardımıyla makine öğrenimi modelleri oluşturulabileceğini ve çalışmaların gelecekte daha da gelişeceğini bildirmişlerdir (Şekil 8).

Dutta (2021) yaptığı çalışmada, koyunları ırklarına göre sınıflandırmayı amaçlamıştır. Temel olarak 4 ırk ele alınmış ve yapay sinir ağları vasıtasıyla koyun ırkları

tanımlanmıştır. Karışık sürüdeki koyunları makine öğrenimi yoluyla tanımlayarak otomatik kapılar aracılığı ile koyunları sınıflandırmış ve bu çalışmada %99,97 başarı elde edildiğini belirtmiştir.



Şekil 8. Koyunlar için otomatik ağrı yüz ifadesi tespit sisteminin geliştirilmesi (McLennan ve Mahmoud, 2019)

Figure 8. Development of automatic pain facial expression detection system for sheep

Dandil ve ark. (2019) tarafından yapılan çalışmada, sığırların yüzlerinden tanınması için Faster R-CNN kullanılarak yüz-temelli bir biyometrik tanıma yaklaşımı uygulamasında sığır yüz görüntüleri %98.44 doğruluk ile başarılı bir şekilde sınıflandırılmıştır (Şekil 9). Araştırmacılar, derin öğrenme kütüphaneleri kullanılarak oluşturulan model ile sığırların kolaylıkla sınıflandırılabilmesinin yanında, yeterli sayıda görüntüye sahip bir veri seti olması durumunda sığırların duygularının tanınmasının da sağlanabileceğini belirtmişlerdir.

SONUÇ

Yapay zekâ uygulamalarının, insan zekâsına özgü donanımları bilgisayar sistemine aktaran bir sistem olması sebebiyle birçok karmaşık işlemi kolay ve hızlı bir şekilde çözüme ulaştırdığı görülmektedir. Günümüzde bilgisayar, algılayıcılar, robot ve yazılım teknolojilerinde yaşanan gelişmeler ışığında yapay zekâ teknolojileri dünya genelinde birçok alanda uygulanmakta olup, tarım alanında da kısa zaman içerisinde hayatımıza daha çok girmesi ve insan müdahalesiyle yapılan birçok görevi üstlenmesi beklenmektedir.

Yapay zekânın, hayvanların duygusal durumları, beslenme alışkanlıkları, süt verimleri, hastalık durumları, yüz tanıma ile sayım ve sınıflandırmaya kadar pek çok alanda, üstelik insan hatasını da ortadan kaldırarak uygulanabilirliği her geçen gün artmaktadır. Bu teknolojilerin hayvancılıkta kullanımları, hem iş

yükünü azaltmakta ve maliyeti düşürmekte, hem de hayvan refahına katkı sağlamaktadır. Gelecekte yapay zekâ teknolojilerinin sektöre entegre edilmesi ve geliştirilmesi ile hayvan yetiştiriciliğinde yaygın kullanımının hem araştırmacılara hem de yetiştiricilere yeni ufuklar açacağı, dünyada ve ülkemizde ilerleyen dönemlerde hayvancılık uygulamalarının daha iyi seviyelere geleceği ve Tarım 4.0 uygulamalarının da yaygınlaşacağı beklenilmektedir.



Şekil 9. Başarılı şekilde tanınan farklı sınıflara ait sığır yüz görüntüleri (Dandil ve ark., 2019)

Figure 9. Facial images of cattle belonging to different classes successfully recognized

KAYNAKLAR

Ağyar Z. 2015. Yapay sinir ağlarının kullanım alanları ve bir uygulama. *Mühendis ve Makine*, 56(662): 22-23.

Andrew NG, Ngiam J, Foo CY, Mai Y, Suen C, Coates A, Tandon S. 2013. Unsupervised feature learning and deep learning. <http://deeplearning.stanford.edu/tutorial/supervised/ConvolutionalNeuralNetwork>. (25.08.2021).

Andrew W, Gao J, Mullan S, Campbell N, Dowsey AW, Burghardt T. 2021. Visual identification of individual Holstein-Friesian cattle via deep metric learning. *Computers and Electronics in Agriculture*, 185, 106133.

Awad AI, Zawbaa HM, Mahmoud HA, Nabi EHHA, Fayed RH, Hassanien AE. 2013. A robust cattle identification scheme using muzzle print images. 2013 Federated Conference on Computer Science and Information Systems, Krakow, Poland. pp. 529-534.

Barbedo JGA, Koenigkan LV. 2018. Perspectives on the use of unmanned aerial systems to monitor cattle. *Outlook on Agriculture*, 47(3), 214-222.

Barry B, Gonzales-Barron UA, McDonnell K, Butler F, Ward S. 2007. Using muzzle pattern recognition as a biometric approach for cattle identification. *Transactions of the ASABE*, 50(3), 1073-1080.

Basheer IA, Hajmeer M. 2000. Artificial neural networks: fundamentals, computing, design, and application. *Journal of Microbiological Methods*, 43(1), 3-31.

Benko A, Lanyi CS. 2009. History of artificial intelligence. In *Encyclopedia of Information Science and Technology*, Second Edition, pp. 1759-1762. IGI Global.

Borchers MR, Chang YM, Proudfoot KL, Wadsworth BA, Stone AE, Bewley JM. 2017. Machine-learning-based calving prediction from activity, lying, and ruminating behaviors in dairy cattle. *Journal of Dairy Science* 100(7):5664-5674.

Bretschneider G, Cuatrin A, Arias D, Vottero D. 2014. Estimation of body weight by an indirect measurement method in developing replacement Holstein heifers raised on pasture. *Archivos de Medicina Veterinaria*, 46(3), 439-443.

Brunassi LDA, Moura DJD, Naas IDA, Vale MMD, Souza SRLD, Lima KAOD, Carvalho TMRD, Bueno LGDF. 2010. Improving detection of dairy cow estrus using fuzzy logic. *Scientia Agricola*, 67(5), 503-509.

Cavero D, Tölle KH, Henze C, Buxadé C, Krieter J. 2008. Mastitis detection in dairy cows by application of neural networks. *Livestock Science*, 114(2-3), 280-286.

Chen LJ, Cui LY, Xing L, Han LJ. 2008. Prediction of the nutrient content in dairy manure using artificial neural network modeling. *Journal of Dairy Science*, 91(12), 4822-4829.

Chowdhary, KR., 2012. Sub-fields and commercial applications of AI. <http://www.krchowdhary.com/ai/ai14/2-ai-applic.pdf> (20.07.2021).

Çetin FA, Mikail N. 2016. Hayvancılıkta veri madenciliği uygulamaları. *Türkiye Tarımsal Araştırmalar Dergisi*, 3(1): 79-88.

Dandil E, Turkan M, Boğa M, Çevik KK. 2019. Daha hızlı bölgesel-evrimsel sinir ağları ile sığır yüzlerinin tanınması. *Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Dergisi*, 6, 177-189.

Dutta PA. 2021. Deep learning approach for animal breed classification - sheep. *International Journal for Research in Applied Science and Engineering Technology*, 9(5), 73-76.

Ermetin O, Mülayim M. 2021. Küçükbaş Hayvan Yetiştiriciliğinde Çoban, Hayvan Davranışları, Sürü Yönetimi ve Teknik Mera Kullanımı. Nobel Yayınları. Yayın No.: 3678, Gıda, Tarım ve Hayvancılık No.: 040. ISBN: 978-625-439-943-5, E-ISBN: 978-625-439-944-2. Ankara.

El Naqa I, Murphy MJ. 2015. What is machine learning? In: El Naqa I, Li R, Murphy MJ (eds), *Machine Learning in Radiation Oncology*. pp. 3-11. Springer, Cham.

Franco MDO, Marcondes MI, Campos JMDS, Freitas DRD, Detmann E, Filho SDCV. 2017. Evaluation of body weight prediction Equations in growing heifers. *Acta Scientiarum. Animal Sciences*, 39(2), 201-206.

- Fuentes S, Gonzalez Viejo C, Cullen B, Tongson E, Chauhan SS, Dunshea FR. 2020. Artificial intelligence applied to a robotic dairy farm to model milk productivity and quality based on cow data and daily environmental parameters. *Sensors*, 20(10), 2975.
- Fuentes S, Gonzalez Viejo C, Tongson E, Lipovetzky N, Dunshea, FR. 2021. Biometric physiological responses from dairy cows measured by visible remote sensing are good predictors of milk productivity and quality through artificial intelligence. *Sensors*, 21(20), 6844.
- Gardner JW, Barlett PN. 1999. *Electronic Noses: Principals and Applications*. Oxford University Press, Oxford, UK.
- Giger ML. 2020. Deep learning. High-dimensional fuzzy clustering. Chicago International Breast Course The Westin Chicago River North.
- Gjergji M, de Moraes Weber V, Silva, LOC, da Costa Gomes R, de Araújo TLAC, Pistori H, Alvarez M. 2020. Deep learning techniques for beef cattle body weight prediction. In 2020 International Joint Conference on Neural Networks (IJCNN), 19-24 July 2020, 1-8.
- Görgülü O. 2012. Prediction of 305-day milk yield in Brown Swiss cattle using artificial neural networks. *South African Journal of Animal Science*, 42(3): 280-287.
- Grzesiak W, Błaszczak P, Lacroix R. 2006. Methods of predicting milk yield in dairy cows—Predictive capabilities of Wood's lactation curve and artificial neural networks (ANNs). *Computers and Electronics in Agriculture*, 54(2), 69-83.
- Hamet P, Tremblay J. 2017. Artificial intelligence in medicine. *Metabolism*, 69, S36-S40.
- He K, Gkioxari G, Dollár P, Girshick R. 2017. Mask R-CNN. *Proceedings of the IEEE International Conference on Computer Vision*. 2961-2969.
- Hertz J, Krogh A, Palmer RG. 1991. *Introduction to the Theory of Neural Computation* (Westview Press).
- Hewitt C, Mahmoud M. 2019. Pose-informed face alignment for extreme head pose variations in animals. In 2019 8th International Conference on Affective Computing and Intelligent Interaction (ACII), pp. 1-6.
- Hornik K. 1991. Approximation capabilities of multilayer feedforward networks. *Neural Networks*. 4(2), 251-257.
- Ikeda Y, Ishii Y. 2008. Recognition of two psychological conditions of a single cow by her voice. *Computers and Electronics in Agriculture*, 62(1), 67-72.
- İnik Ö, Ülker E. 2017. Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104.
- Jones LD, Golan D, Hanna SA, Ramachandran M. 2018. Artificial intelligence, machine learning and the evolution of healthcare: a bright future or cause for concern? *Bone & Joint Research*, 7(3), 223-225.
- Jung DH, Kim NY, Moon SH, Jhin C, Kim HJ, Yang JS, Kim HS, Lee TS, Lee JY, Park SH. 2021. Deep learning-based cattle vocal classification model and real-time livestock monitoring system with noise filtering. *Animals*, 11, 357.
- Kaler J, Daniels SLS, Wright JL, Green LE. 2010. Randomised clinical trial of long-acting oxytetracycline, foot trimming, and flunixin meglumine on time to recovery in sheep with footrot. *Journal of Veterinary Internal Medicine*, 24(2), 420-425.
- Kumar S, Singh SK. 2017. Visual animal biometrics: survey. *IET Biometrics*, 6(3), 139-156.
- Kumar S, Singh SK, Dutta T, Gupta, HP. 2016. A fast cattle recognition system using smart devices. *Proceedings of the 24th ACM International Conference on Multimedia*. 742-743.
- Kumar S, Pandey A, Satwik KSR, Kumar S, Singh SK, Singh AK, Mohan A. 2018. Deep learning framework for recognition of cattle using muzzle point image pattern. *Measurement*, 116: 1-17.
- Langford DJ, Bailey AL, Chanda ML, Clarke SE, Drummond TE, Echols S, Glick S, Ingra J, Klassen-Ross T, Lacroix-Fralish ML, Matsumiya L, Sorge RE, Sotocinal SG, Tabaka JM, Wrong D, van den Maagdenberg AMJM, Ferrari MD, Craig KD, Mogil JS. 2010. Coding of facial expressions of pain in the laboratory mouse. *Nature Methods*, 7(6), 447-449.
- Liddy ED. 2001. *Natural Language Processing*. In *Encyclopedia of Library and Information Science*, 2nd Ed. NY. Marcel Decker, Inc.
- Ma C, Sun X, Yao C, Tian M, Li L. 2020. Research on sheep recognition algorithm based on deep learning in animal husbandry. *Journal of Physics: Conference Series Vol. 1651, 012129*. IOP Publishing.
- Madan P, Madhavan S. 2020. An introduction to deep learning. <https://developer.ibm.com/articles/an-introduction-to-deep-learning/> (25.08.2021).
- Mahmoud M, Lu Y, Hou X, McLennan K, Robinson P. 2018. Estimation of Pain in Sheep Using Computer Vision. In: Moore RJ (ed.). *Handbook of Pain and Palliative Care: Biopsychosocial and Environmental Approaches for the Life Course*. pp. 145-157. Springer, Cham.
- Mataric MJ. 2007. *The Robotics Primer*. The MIT Press. 328 pp.
- McLennan K, Mahmoud M. 2019. Development of an automated pain facial expression detection system for sheep (*Ovis Aries*). *Animals*, 9(4), 196.
- Memmedova N, Keskin İ. 2011. İneklerde bulanık mantık modeli ile hareketlilik ölçüsünden yararlanılarak kızgınlık tespiti. *Kafkas Üniversitesi Veteriner Fakültesi Dergisi*, 17(6), 1003-1008.
- Memmedova N. 2012. Süt Sığırlarında Mastitisin Bazı Yapay Zekâ Yöntemleri Kullanılarak Erken Dönemde Tespiti. *Doktora Tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Zootekni Anabilim Dalı, Konya*.
- Nabiyev VV. 2012. *Yapay Zekâ: İnsan-Bilgisayar Etkileşimi*. Seçkin Yayıncılık. ISBN: 9789750220340.
- Neethirajan S. 2021. Happy cow or thinking pig? WUR wolf-Facial coding platform for measuring emotions in farm animals. *AI*, 2(3), 342-354.
- Norouzadeh MS, Nguyen A, Kosmala M, Swanson A, Palmer MS, Packer C, Clune J. 2018. Automatically identifying, counting, and describing wild animals in camera-trap

- images with deep learning. Proceedings of the National Academy of Sciences, 115(25), E5716-E5725.
- O'Mahony N, Campbell S, Carvalho A, Harapanahalli S, Hernandez GV, Krpalkova L, Walsh J. 2019. Deep learning vs. traditional computer vision. In Science and Information Conference, CVC 2019, pp. 128-144. Springer, Cham.
- Öztürk K, Şahin ME. 2018. Yapay sinir ağları ve yapay zekâ'ya genel bir bakış. Takvim-i Vekayi, 6(2), 25-36.
- Pan L, Yang SX. 2007. A new intelligent electronic nose system for measuring and analysing livestock and poultry farm odours. Environmental Monitoring and Assessment, 135: 399-408.
- Poole GD, Craig KD. 1992. Judgments of genuine, suppressed, and faked facial expressions of pain. Journal of Personality and Social Psychology, 63(5), 797-805.
- Porter S, ten Brinke L, Wallace B. 2012. Secrets and lies: Involuntary leakage in deceptive facial expressions as a function of emotional intensity. Journal of Nonverbal Behavior, 36(1), 23-37.
- Powers WJ, Bastyr S. 2004. Downwind air quality measurements from poultry and livestock facilities. Animal Industry Report: ASL-R1927. Ames, IA: Iowa State University.
- Preece J, Rombach HD. 1994. A taxonomy for combining software engineering and human-computer interaction measurement approaches: towards a common framework. International Journal of Human-Computer Studies, 41(4), 553-583.
- Qu G, Feddes JJR, Armstrong WW, Coleman RN, Leonard JJ. 2001. Measuring odour concentration with an electronic nose. Transactions of the ASAE, 44(6), 1807-1812.
- Reis GL, Albuquerque FHMAR, Valente BD, Martins GA, Teodoro RL, Ferreira MBD, Monteiro JBN, e Silva MDA, Madalena FE. 2008. Predição do peso vivo a partir de medidas corporais em animais mestiços Holandês/Gir. Ciência Rural, 38(3), 778-783.
- Ren S, He K, Girshick R, Sun J. 2017. Faster R-CNN: Towards real-time object detection with region proposal networks. IEEE Transactions on Pattern Analysis and Machine Intelligence, 39(6), 1137-1149.
- Roberts HC, Elbers ARW, Conraths FJ, Holsteg M, Hoereth-Boentgen D, Gethmann J, van Schaik G. 2014. Response to an emerging vector-borne disease: Surveillance and preparedness for Schmallenberg virus. Preventive Veterinary Medicine, 116(4), 341-349.
- Takma Ç, Atıl H, Aksakal V. 2012. Çoklu doğrusal regresyon ve yapay sinir ağı modellerinin laktasyon süt verimine uyum yeteneklerinin karşılaştırılması. Kafkas Üniversitesi Veteriner Fakültesi Dergisi, 18(6): 941-944.
- Terzi İ, Özgüven MM, Altaş Z, Uygun T. 2019. Tarımda yapay zekâ kullanımı. International Erciyes Agriculture, Animal & Food Sciences Conference 24-27 April 2019 - Erciyes University - Kayseri, Turkey. 245-255.
- van Gerven M, Bohte S. 2017. Editorial: Artificial neural networks as models of neural information processing. Frontiers in Computational Neuroscience, 11: 114.
- Xu B, Wang W, Falzon G, Kwan P, Guo L, Chen G, Tait A, Schneider D. 2020. Automated cattle counting using Mask R-CNN in quadcopter vision system. Computers and Electronics in Agriculture, 171, 105300.
- Yıldız AK. 2016. Büyükbaş Hayvanlarda Kızgınlığın (Östrus) Hareketlilik ve Çevre Verilerinden Yararlanarak Yapay Sinir Ağları İle Belirlenmesi. Doktora Tezi. Gaziosmanpaşa Üniversitesi Fen Bilimleri Enstitüsü, Biyosistem Mühendisliği Ana Bilim Dalı. Tokat.
- Zhang Z. 2018. Artificial Neural Network. In: Multivariate Time Series Analysis in Climate and Environmental Research. Springer, Cham. pp. 1-35.
- Zhang XD. 2020. Machine Learning. In A Matrix Algebra Approach to Artificial Intelligence. Springer, Singapore. pp. 223-440.