

Prediction of Chicken Diseases by Transfer Learning Method

Mustafa Can Bingol ^a, Gürkan Bilgin ^{b,1}

^a Burdur Mehmet Akif Ersoy Üniversitesi, Mühendislik Mimarlık Fakültesi, Turkey
ORCID ID: 0000-0001-5448-8281

^b Burdur Mehmet Akif Ersoy Üniversitesi, Mühendislik Mimarlık Fakültesi, Turkey
ORCID ID: 0000-0002-8441-1557

Abstract

With the development of computing technologies, artificial intelligence is used in a wide range of areas, from engineering to healthcare. In this study, it was aimed to predict chicken diseases with transfer learning. For this purpose, a ready-made data set was studied. This data set contains fecal photographs of healthy chickens diagnosed with Coccidiosis, Newcastle and Salmonella diseases. The data set has been subjected to necessary pre-processing such as size readjustment. Subsequently, the data set, which was then subjected to pre-processing, was divided into 70% and 30% as training and testing. To solve the disease classification problem, a network was created by adding fully connected layers to ResNet50, InceptionV3, InceptionResNetV2, Xception and MobileNetV2 architectures. The weights of the architectures mentioned in these networks were selected as ImageNet and were not trained. Then, networks containing these architectures were trained using the training data set. The trained networks were validated with the test data set and accuracy rates of 32.7%, 80.6%, 85.2%, 89.2% and 90.7% were obtained, respectively. According to these results, MobileNetV2 was used in the proposed artificial neural network architecture since the best result was calculated using the MobileNetV2 architecture. The proposed artificial neural network architecture was trained with the same training set and validation was carried out with the same test data set. After these procedures, the true prediction rate of the proposed architecture for the test data set was calculated as 92.1%. Also, F1 score of the proposed architecture was measured 0.923. Additionally, thanks to the deconvolution layer used in the proposed architecture, network sizes have been reduced by approximately 50%. Thanks to this reduction, the training time is shortened and it becomes easier to implement it on embedded systems in future studies. As a result, the diseases of chickens were predicted largely accurately with the transfer learning method.

Keywords: “Transfer learning, deconvolution, neural network.”

1. Giriş

Tavuk eti, kaliteli protein, düşük yağ oranı, zengin vitamin-mineral içeriği ve düşük maliyetinden dolayı insanlar tarafından sıklıkla tercih edilen bir besindir. Her organizma gibi tavuklarda içerisinde bulunduğu çevrede parazitler, virüsler ve bakteriler gibi bir çok tehdit ile karşı karşıyadır. Örneğin, Eimeria cinsi apikompleksan protozoonları ile enfekte olan bir tavuk, Koksidiyoz hastalığına yakalanmış olur. Bu hastalık intestinal kanalda gelişim gösterdiği için ağırlık artışının yavaşlaması ve ikincil bakteriyel enfeksiyona karşı duyarlılık artışı gibi semptomlar ile enfekte olmuş bir tavuğu öldürebilir [1]. 1926 yılında İngiltere'nin Newcastle şehrinde ilk defa görülen Newcastle hastalığı virüs kaynaklı bir hastalıktır. Bu hastalık akut şekilde tavukların bağırsaklarında oluşan öldürücü bir hastalıktır [2]. Salmonella patojenik bakteri türü bir çok hayvanda semptomatik enfeksiyona neden olur. Bu bakteri türünün bazı serotipleri aynı zamanda insana gıda kaynaklı bulaşabilir. Bu serotiplerden biri olan Salmonella Gallinarum bakterisi ile enfekte olmuş ergin tavuklarda ölüm oranının %10-93 değerlerinde olduğu rapor edilmiştir [3].

Günümüzde gelişen teknoloji ile birlikte yapay zeka uygulamaları robotikten [4] sağlığa [5,6,7] ve ahşap yapı malzemelerine [8] kadar birçok alanda kullanılmaktadır. Örneğin Zu ve ekibi, tavuklarda üreme verimini arttırabilmek için vücut ısılarını ölçebilme gerekliliği problemini belirlemişlerdir. Bu problemin çözümü için, en doğru vücut ısını ağızlarından alınabileceği belirtilmiş ve bu doğrultuda gagalarının açık olup olmadığını ayıran bir yapay sinir ağı geliştirmişlerdir [9]. Bir diğer çalışmada, bir makine öğrenimi yöntemi olan Destek Vektör Makinası (DVM) kullanarak bir çiftlikte bulunan ölü tavukları algılayan bir uygulama geliştirmişlerdir [10]. Bakar ve arkadaşları 2022 yılında tavukların kafalarının görüntülerini enfekte ve sağlıklı olarak sınıflandırmışlardır [11]. Bir diğer çalışmada çiftlikte bulunan tavukların yerinin tespit edilmesi problemi yapay sinir ağı kullanılarak çözülmüştür [12]. Chen ve ekibi ise çiftlikteki tavukların anormal bir dağılımında olup olmadığını tespit eden bir uygulamayı makine öğrenmesi ve derin öğrenme algoritmalarından yararlanarak geliştirmişlerdir [13].


¹ Corresponding Author
E-mail Address: gbilgin@mehmetakif.edu.tr

Öğrenme transferi, daha önceden başka bir veri seti kullanılarak eğitilen bir yapay sinir ağı ağırlıklarının benzer bir problem için iyileştirilmesidir. Bu sayede ağırlıklar, uzun süre tekrar eğitimden kısa bir sürede arzu edilen yeni veri seti için iyileştirilmiş olur. Literatürde bu yöntemi kullanan çalışmalar mevcuttur. Örneğin, geleneksel bir robot, öğrenme transferi kullanılarak asistan bir robota dönüştürülmüştür [14]. Bir diğer çalışmada, sığırların analizinde kullanılmak üzere ön meme yerleşim pozisyonunu bulabilecek bir uygulamayı öğrenme transferi yöntemi ile gerçekleştirmişlerdir. Yapılan bu çalışmadan önceden eğitilmiş mimari olarak MobileNet, Xception ve VGG16 kullanılmıştır [15]. Bir diğer çalışmada ise sığırların ayak ve ağız hastalıkları MobileNetV2 kullanılarak sınıflandırılmıştır [16]. Hao ve ark. bireysel sığır tanıma sistemi gerçekleştirmeyi hedeflemişlerdir. Bu hedef doğrultusunda geliştirdikleri uygulamanın temel yapı taşlarından biri öğrenme transferi olmuştur [17].

Yapılan bu çalışmada tavuk dışkılarının görüntüleri kullanılarak tavukların sağlıklı veya hasta olup olmadıkları ve hasta tavuklarda ise hastalık türünün tespit edilmesi planlanmıştır. Bu amaç doğrultusunda hasta tavuklarda hastalık çeşitlerinin ve herhangi bir hastalığı bulunmayan sağlıklı tavukların ayırımının yapılabilmesi için önceden eğitilmiş yapay sinir ağı yapısının bir başka problem için iyileştirilmesi esasına dayanan öğrenme transferi işlemi kullanılmıştır. Uygulanacak işlem basamakları ve ayrıntılı anlatımı materyal ve metod bölümünde açıklanmıştır. Ayrıca materyal ve metod bölümünde çalışmada kullanılan veri setinin hangi hastalıkları barındırdığından ve veri seti içerisindeki görüntü sayılarından bahsedilmiştir. Çalışmada kullanılan mimariler hakkında bilgiler yine materyal ve metod bölümünde verilmiştir. Son bölüm olan bulgular bölümünde ise eğitim ve test veri setleri kullanılarak yapılan analizlerin kayıp fonksiyonu ve doğruluk değerleri sonuçlarına göre mimarilerin karşılaştırma grafikleri sunulmuştur. Ayrıca yine bulgular bölümünde eğitilen mimarilerin toplam parametre sayıları ve eğitilen parametre sayıları verilmiş, eğitim sonrası test veri setine göre elde edilen kesinlik, duyarlılık, F1 skoru ve yüzde doğruluk değerleri verilmiştir. Sonuç ve tartışma kısmında ise elde edilen bulgular yorumlanarak gelecek çalışma perspektifi çizilmeye çalışılmıştır. Bu plan doğrultusunda yazının devamı materyal metod, bulgular, sonuç ve tartışma olarak organize edilmiştir.

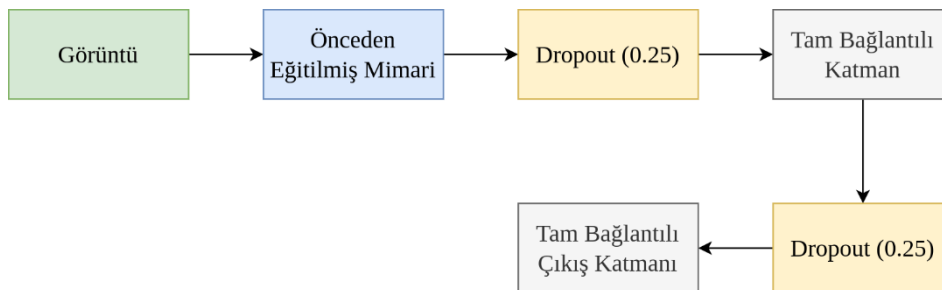
2. Materyal ve Metod

Yapılan çalışmada, tavuk hastalıkları görüntü sınıflandırması veri seti [18] kullanılmıştır. Bu veri seti içerisinde toplam 8067 adet tavuk dışkısı fotoğrafı vardır. Bu dışkı görüntüleri, Koksidiyoz hastalığı (2476), Newcastle hastalığı (562), Salmonella hastalığı (2625) olan ve herhangi bir hastalığı bulunmayan sağlıklı (2404) tavuk dışkılarından oluşmaktadır. Bu veri seti sabit disk üzerinde 294,1 MB yer kaplamaktadır. Veri setine ait görüntüler ve ait olunan sınıflar Şekil 1’de sunulmuştur.



Şekil 1. Veri setine ait görüntüler, (a) Koksidiyoz Hastalığı, (b) Newcastle Hastalığı, (c) Salmonella Hastalığı, (d) Sağlıklı.

Görüntüler veri setinden elde edildikten sonra öğrenme transferi işlemi Şekil 2’de sunulan yöntem ile gerçekleştirilmiştir.




Şekil 2. Öğrenme transferi blok diyagramı.

Görüntü sabit disk üzerinden okuduktan sonra ilk olarak önceden eğitilmiş mimarilerde işleme tabi tutulmuştur. Yapılan bu çalışmada kullanılan mimariler sırası ile ResNet50 [19], InceptionV3 [20], InceptionResNetV2 [21], Xception [22] ve MobileNetV2’dir [23]. Kullanılan bu mimarilerin giriş boyutu [224,224,3] olarak ayarlanmıştır. Ayrıca, ağırlıkları ImageNet olarak başlatılmış ve eğitim sırasında korunmuştur. Önceden eğitilmiş mimarinin ve tam bağlantılı katmanın çıkışlarına eğitim

sırasında yaşanabilecek aşırı uyum problemini giderebilmek için %25 ayırma işlemini yapabilecek Dropout katmanları bırakılmıştır. Bu katmanın görevi eğitim sırasında bazı bağlantıları yok sayarak eğitilen mimarinin daha gürbüz cevap vermesini sağlamaktır. Ayrıca, ilk Dropout katmanından önce evrişimli sinir ağı çıkışının boyutunu tam bağlantılı katmana giriş olarak uygulayabilmek için $1 \times N$ boyutuna çevirebilecek düzleştirme katmanı kullanılmıştır. Tam bağlantılı katmanın görevi bir önceki katmanın bütün nöronları ile bağlantı kurarak çıkış üretmektedir. Yapılan bu çalışmada tam bağlantılı katmanda bulunan nöron sayısı 32 olarak belirlenmiştir ve aktivasyon fonksiyonu olarak doğrusallaştırılmış liner birim olan (Rectified Linear Unit - ReLU) seçilmiştir. ReLU, 0' dan küçük değerler için 0, diğer durumlarda ise değer kendisini üreten bir fonksiyondur. Yaptığı bu matematiksel işlemde dolayı türevi en kolay alınan aktivasyon fonksiyonu olup eğitim süresinin kısaltılabilmesi için bu fonksiyon seçilmiştir. Tam bağlantılı çıkış katmanı bir tam bağlantılı katman benzeri olup, nöron sayısı 4 ve aktivasyon fonksiyonu olarak Softmax seçilmiştir. Eğitim sırasında kayıp fonksiyonu olarak Denklem 1' de sunulan Kategorik Çapraz Kayıp Fonksiyonu seçilmiştir. Bu Denklem 1' de L kayıp fonksiyonunu, i veri sayısını, n çıkış boyutunu, y_i gerçek değeri, \hat{y}_i tahmin edilen değeri göstermektedir. Bu katmandaki nöron sayısı sınıf sayısını temsil etmekte olup, aktivasyon fonksiyonu da yine sınıflandırma problemine özgü seçilmiştir.

$$L = - \sum_{i=1}^n y_i \cdot \log \hat{y}_i \quad (1)$$

Yapılan bu çalışmada ilk olarak önceden eğitilmiş mimariler tekrardan eğitilmiştir. Bu eğitim sırasında test verilerine göre en iyi sonucu MobileNetV2 mimarisi üretmiştir. Bu sebepten dolayı önerilen yöntemde MobileNetV2 tabanlı bir mimari olan yapı Şekil 3' te görselleştirilmiştir.




Şekil 3. Çalışmada önerilen mimari.

Şekil 3' te sunulan mimaride bulunan tam bağlantılı katman ve tam bağlantılı çıkış katmanının hiper-parametreleri Şekil 2' de sunulan mimari ile aynıdır. Önerilen mimarinin Şekil 2' de sunulan mimariden farkı ise ters evrişim katmanıdır. Ters evrişim işlemi, literatürde görüntü segmentasyon probleminde sıkça yararlanılan bir yöntem olup, bir görüntü üzerinde özelliklere bağlı olarak belirli eşikleme işlemi gerçekleştirilmesi için kullanılmaktadır. Yapılan bu çalışmada ise ters evrişim katmanının kullanılmasının iki temel amacı vardır. Bunlardan ilki, eğitilmiş mimari çıkışında elde edilen özelliklerin ayrıştırılmasıdır. Bu sayede mimari çıkışında elde edilen özellikler daha etkili olarak yorumlanabilecektir. İkincisi ise bir nevi darboğaz görevi verilerek, eğitim performansının artmasının yanı sıra eğitilecek parametre sayısını düşürüp eğitim süresini hızlandırmaktır. Bu sebepten dolayı ters evrişim katmanının filtre sayısı 32 olarak belirlenmiştir. Ayrıca, kernel boyutu ve aktivasyon fonksiyonu sırası ile 3×3 ve ReLU olarak seçilmiştir. Eğitim performans parametreleri Denklem 2' de sunulan Doğruluk oranı formülü ile tespit edilmiştir.

$$\text{Doğruluk oranı} = \frac{\text{Doğru Tahmin Edilen Sınıf Sayısı}}{\text{Toplam Örnek Sayısı}} \quad (2)$$


3. Bulgular

Yapılan bu çalışmada kullanılan tavuk hastalıkları veri setinde toplam 8067 görüntü dosyası vardır. Bu görüntü dosyalarının %70'i eğitim ve %30'u test için ayrılmıştır. Eğitim aşamasında önceden eğitilmiş mimarilerin ağırlıkları korunmuştur. Eğitim işlemi toplam 10 adımda gerçekleştirilmiştir. Yiğın boyutu (batch size) 32 olarak seçilmiştir. Ağ eğitim yöntemi ve kayıp fonksiyonu olarak sırası ile adaptif moment yaklaşımı algoritması ve kategorik çapraz entropi fonksiyonu kullanılmıştır. Ayrıca, öğrenme oranı 10^{-3} olarak seçilmiştir. Ayarlanan bu hiper parametreler ile mimarilerin eğitim performans grafikleri Şekil 4'te sunulmuştur.



Şekil 4. Eğitim veri setinin eğitim performans grafikleri, (a) Kayıp fonksiyonu değerleri, (b) Doğruluk değerleri.

Eğitim işlemi sırasında eğitim verilerine göre elde edilen kayıp fonksiyonu ve doğruluk değerleri grafikleri Şekil 4' te sunulmuştur. Sunulan bu grafiklerde bulunan doğruluk değerleri, sınıfı doğru tahmin edilen görüntü sayısının toplam görüntü sayısına oranını sembolize etmektedir. Bu gerçekleştirilen eğitim sırasında test veri setine ait kayıp fonksiyonu ve doğruluk değerleri grafikleri Şekil 5' te sunulmuştur.



Şekil 5. Test veri setinin performans grafikleri, (a) Kayıp fonksiyonu değerleri, (b) Doğruluk değerleri

Şekil 5-b' de sunulan test veri setinin 10. adım sonrası doğruluk değerleri Tablo 1' de verilmiştir.

Tablo 1. Mimarilerin parametre sayıları ve test veri setine göre doğruluk oranları.

Mimari	Toplam Parametre Sayısı	Eğitilen Parametre Sayısı	Kesinlik	Duyarlılık	F1 Skoru	Doğruluk (%)
ResNet50	26.8 M	3.2 M	0	0	Nan	32.7
InceptionV3	23.4 M	1.6 M	0.857	0.750	0.800	80.6
InceptionResNetV2	55.5 M	1.2 M	0.919	0.834	0.874	85.2
Xception	24.0 M	3.2 M	0.914	0.880	0.896	89.2
MobileNetV2	4.3 M	2.2 M	0.938	0.846	0.889	90.7
Önerilen Mimari	2.7 M	0.4 M	0.927	0.918	0.923	92.1

Tablo 1' de çalışmada eğitilen mimarilerin toplam parametre sayıları, eğitilen parametre sayıları verilmiştir. Ayrıca, eğitim sonrası test veri setine göre elde edilen kesinlik, duyarlılık, F1 skoru ve yüzde doğruluk değerleri olarak verilmiştir. Yapılan bu çalışmada önceden eğitilmiş mimarilerin ağırlıkları korunduğundan dolayı toplam parametre ile eğitilen parametre sayısı farklıdır. Toplam parametre ile eğitilen parametre sayısının farkı önceden eğitilmiş mimarilerin parametre sayılarını vermektedir.

Eğitilen parametre sayısı ise Şekil 2 ve 3' te sunulan önceden eğitilmiş mimari sonrasında bulunan katmanlarda bulunan nöronları temsil etmektedir.

4. Sonuçlar ve Tartışma

Yapay zeka günümüzde mühendislikten sağlık alanına kadar her alanda sıklıkla kullanılmaktadır. Yapılan bu çalışmada tavuk hastalıklarının yapay zeka tabanlı tanı koyulup koyulamayacağı araştırılması amaçlanmıştır. Bu amaç doğrultusunda ilk olarak veri seti elde edilmiştir. Elde edilen bu veri seti ön işlem olarak 224x224 boyutunda RGB formatında ayarlanmıştır. Daha sonra bu görüntüler rastsal olarak %70 ve %30 oranında eğitim ve test olarak ayrılmıştır. Eğitim veri seti olarak ayrılan görüntüler Şekil 2' de sunulan mimarinin eğitiminde kullanılmıştır. Bu eğitim sırasında önceden eğitilmiş mimari olarak sırası ile ResNet50, InceptionV3, InceptionResNetV2, Xception ve MobileNetV2 yapıları kullanılmıştır. Bu mimarilerin test veri seti kullanılarak doğruluk oranları sırası ile 32.7, 80.6, 85.2, 89.2 ve 90.7 olarak hesaplanmıştır. En iyi sonucu MobileNetV2 mimarisi kullanılarak elde edildiğinden dolayı önerilen mimari (bkz. Şekil 3) önceden eğitilmiş mimari olarak MobileNetV2 kullanılmıştır. Önerilen bu mimari yine aynı eğitim veri seti ile eğitilmiştir. Eğitilen bu mimarinin F1 skoru ve doğruluk oranı ise sırası ile 0.923 ve %92.1 olarak hesaplanmıştır. Bu değer diğer mimarilerle kıyaslandığında en iyi değerdir. Önerilen mimarinin önceki mimarilerden farkı ters evrişim katmanının kullanılmasıdır. Bu katman sayesinde Tablo 1' de görüldüğü üzere eğitilen parametre sayısı ve toplam parametre sayısı azalmıştır. Parametre sayısının azalması bu tür bir sistemin gömülü hale getirilmesini daha kolaylaştırmasının yanı sıra eğitim süresini de kısaltmıştır.

Gelecek çalışmamızda ilk olarak daha geniş bir veri seti hazırlanacaktır. Hazırlanan bu veri setindeki hastalık sayısı arttırılacaktır. Hazırlanacak veri seti ile bu çalışmada önerilen mimari denenecek ve daha yüksek doğruluk oranlarına çıkabilmesi için gelişmiş yapılar denenecektir.

Referanslar

- [1] U. Uslu and O. Ceylan, "Serbest Dolaşımli üretim Sisteminde Yetiştirilen hubbard isa red-ja broyler tavuklardaki Sekal Koksidiyozun Tedavisinde toltrazuril'in (COC-CIDE®) Etkinliğinin Değerlendirilmesi," Dicle Üniversitesi Veteriner Fakültesi Dergisi, vol. 13, no. 2, pp. 135–138, 2020. doi:10.47027/duvetfd.816477.
- [2] A. Mimbay, "Newcastle hastalığının korunma ve kontrolü," Etlik Veteriner Mikrobiyoloji Dergisi ,vol. 5 no. 1-2-3, pp. 128-137.
- [3] H. Yardımcı, and A. Aksoy, "Tavuklarda Salmonella infeksiyonlarının kontrolü," Etlik Veteriner Mikrobiyoloji Dergisi , vol. 25, no. 2, pp. 63-72.
- [4] M. C. Bingol and O. Aydogmus, "Practical application of a safe human-robot interaction software," Industrial Robot: the international journal of robotics research and application, vol. 47, no. 3, pp. 359–368, 2020. doi:10.1108/ir-09-2019-0180.
- [5] B. Gürkan and A. Çifçi, "Eritematöz Skuamöz Hastalıkların Teşhisinde Makine Öğrenme Algoritmalarının Etkisi." Journal of Intelligent Systems: Theory and Applications vol. 4, no. 2, pp. 195-202, 2021.
- [6] B. Gürkan, "Makine öğrenmesi algoritmaları kullanarak erken dönemde diyabet hastalığı riskinin araştırılması." Journal of Intelligent Systems: Theory and Applications, vol. 4, no. 1, pp.55-64, 2021.
- [7] N. E. M. Khalifa, M. H. N. Taha, D. Ezzat Ali, A. Slowik and A. E. Hassanien, "Artificial Intelligence Technique for Gene Expression by Tumor RNA-Seq Data: A Novel Optimized Deep Learning Approach," IEEE Access, vol. 8, pp. 22874-22883, 2020, doi: 10.1109/ACCESS.2020.2970210.
- [8] K. İsmail and A. Çifci. "An effective and fast solution for classification of wood species: A deep transfer learning approach." Ecological Informatics, vol. 69, pp. 195-202, 2022.
- [9] L. Zu, X. Chu, Q. Wang, Y. Ju and M. Zhang, "Joint Feature Target Detection Algorithm of Beak State Based on YOLOv5," IEEE Access, vol. 11, pp. 64458-64467, 2023, doi: 10.1109/ACCESS.2023.3275432.
- [10] W. Zhu, Y. Peng and B. Ji, "An Automatic Dead Chicken Detection Algorithm Based on SVM in Modern Chicken Farm," 2009 Second International Symposium on Information Science and Engineering, Shanghai, China, 2009, pp. 323-326, doi: 10.1109/ISISE.2009.62.

- [11] M. A. A. A. Bakar, P. J. Ker, S. G. H. Tang, H. J. Lee and B. S. Zainal, "Classification of Unhealthy Chicken based on Chromaticity of the Comb," 2022 IEEE International Conference on Computing (ICOCO), Kota Kinabalu, Malaysia, 2022, pp. 1-5, doi: 10.1109/ICOCO56118.2022.10031812.
- [12] Y. Guo et al., "Detecting broiler chickens on litter floor with the Yolov5-CBAM Deep Learning Model," *Artificial Intelligence in Agriculture*, vol. 9, pp. 36–45, 2023. doi:10.1016/j.aiia.2023.08.002.
- [13] B.-L. Chen et al., "Developing an automatic warning system for anomalous chicken dispersion and movement using Deep Learning and machine learning," *Poultry Science*, vol. 102, no. 12, p. 103040, 2023. doi:10.1016/j.psj.2023.103040.
- [14] M. C. Bingol and O. Aydogmus, "Development of a Human-Robot Interaction System for Industrial Applications," *Balkan Journal of Electrical and Computer Engineering (BAJECE)*, vol. 1, no. 1, pp. 1–10, 2023.
- [15] H. Afridi, M. Ullah, Ø. Nordbø, A. G. Larsgard and F. Alaya Cheikh, "Leveraging Transfer Learning for Analyzing Cattle Front Teat Placement," 2023 Twelfth International Conference on Image Processing Theory, Tools and Applications (IPTA), Paris, France, 2023, pp. 1-6, doi: 10.1109/IPTA59101.2023.10320080.
- [16] R. N. Shebiah and S. Arivazhagan, "Deep Learning Based Image Analysis for Classification of Foot and Mouth Disease in Cattle," 2023 5th International Conference on Inventive Research in Computing Applications (ICIRCA), Coimbatore, India, 2023, pp. 701-705, doi: 10.1109/ICIRCA57980.2023.10220765.
- [17] W. Hao et al., "A novel jinnan individual cattle recognition approach based on mutual attention learning scheme," *Expert Systems with Applications*, vol. 230, p. 120551, 2023. doi:10.1016/j.eswa.2023.120551
- [18] Allandclive, "Chicken disease image classification," Kaggle, <https://www.kaggle.com/datasets/allandclive/chicken-disease-1> (accessed Nov. 24, 2023).
- [19] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016. doi:10.1109/cvpr.2016.90.
- [20] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, "Rethinking the inception architecture for computer vision," 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016. doi:10.1109/cvpr.2016.308.
- [21] C. Szegedy, S. Ioffe, V. Vanhoucke, and A. Alemi, "Inception-V4, inception-resnet and the impact of residual connections on learning," *Proceedings of the AAAI Conference on Artificial Intelligence*, vol. 31, no. 1, 2017. doi:10.1609/aaai.v31i1.11231.
- [22] F. Chollet, "Xception: Deep learning with depthwise separable convolutions," 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017. doi:10.1109/cvpr.2017.195.
- [23] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L.-C. Chen, "MobileNetV2: Inverted residuals and linear bottlenecks," 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018. doi:10.1109/cvpr.2018.00474.