



T.C.

**YOZGAT BOZOK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
TARIM BİLİMLERİ ANABİLİM DALI**

**DERİN ÖĞRENME VE GELENEKSEL MAKİNE ÖĞRENME
TEKNİKLERİ KULLANILARAK MANDA YÜZ TANIMA
MODELLERİNİN GELİŞTİRİLMESİ**

NİYAZİ HAYRULLAH TUVAY

YÜKSEK LİSANS TEZİ

Danışman: Dr. Öğr. Üyesi Orhan ERMETİN

KASIM – 2023

YOZGAT

T.C
YOZGAT BOZOK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
TARIM BİLİMLERİ ANABİLİM DALI

DERİN ÖĞRENME VE GELENEKSEL MAKİNE ÖĞRENME
TEKNİKLERİ KULLANILARAK MANDA YÜZ TANIMA
MODELLERİNİN GELİŞTİRİLMESİ

NİYAZİ HAYRULLAH TUVAY

YÜKSEK LİSANS TEZİ

Danışman: Dr. Öğr. Üyesi Orhan ERMETİN

Bu çalışma TÜBİTAK tarafından 1002/122E313 kodu ile desteklenmiştir.

KASIM – 2023

YOZGAT



YOZGAT BOZOK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
LİSANSÜSTÜ TEZ ONAY FORMU

T.C.

YOZGAT BOZOK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

Enstitümüzün Tarım Bilimleri Anabilim Dalı Tezli Yüksek Lisans Programı öğrencisi Niyazi Hayrullah TUVAY'ın hazırladığı “**Derin Öğrenme Ve Geleneksel Makine Öğrenme Teknikleri Kullanılarak Manda Yüz Tanıma Modellerinin Geliştirilmesi**” başlıklı tezi ile ilgili tez savunma sınavı, Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliği'nin ilgili maddeleri gereğince 24/11/2023 Cuma günü saat 14:30'da yapılmış, tezin onayına oy birliği ile karar verilmiştir.

Başkan : Dr. Öğr. Üyesi Orhan ERMETİN
(Danışman)

Jüri Üyesi : Doç. Dr. Ertuğrul KUL

Jüri Üyesi : Dr. Öğr. Üyesi Tolga HAYIT

ONAY:

Bu tezin kabulü, Enstitü Yönetim Kurulu'nun/...../..... tarih ve sayılı Enstitü Yönetim Kurulu Kararı ile onaylanmıştır.

...../...../.....

Prof. Dr. Hasan Güner BERKANT

Lisansüstü Eğitim Enstitüsü Müdürü

TEZ BEYANI

Tez yazım kurallarına uygun olarak hazırlanan bu tezin yazılmasında bilimsel ahlak kurallarına uyulduğunu, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezin içerdığı yenilik ve sonuçların başka bir yerden alınmadığını, kullanılan verilerde herhangi bir tahrifat yapılmadığını, tezin herhangi bir kısmının bu üniversite veya başka bir üniversitedeki başka bir tez çalışması olarak sunulmadığını beyan eder, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Niyazi Hayrullah TUVAY

24/11/2023

ÖNSÖZ

Bu çalışmada maddi, manevi desteklerini benden esirgemeyen, zor zamanlarımda hep yanımda olan ve başarılı olmam için insanüstü bir gayret gösteren danışman hocam sayın Dr. Öğr. Üyesi Orhan ERMETİN'e, eşsiz yardımları ile bana destek olan hocam sayın Dr. Öğr. Üyesi Tolga HAYIT'a teşekkürü bir borç bilirim.

Ayrıca, desteği ile her zaman yanımda olan canım annem Meşküre TUVAY'a sonsuz teşekkürlerimi sunarım.

Niyazi Hayrullah TUVAY

24/11/2023

ÖZET

YÜKSEK LİSANS TEZİ

DERİN ÖĞRENME VE GELENEKSEL MAKİNE ÖĞRENME TEKNİKLERİ KULLANILARAK MANDA YÜZ TANIMA MODELLERİNİN GELİŞTİRİLMESİ

NİYAZİ HAYRULLAH TUVAY

YOZGAT BOZOK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
TARIM BİLİMLERİ ANABİLİM DALI

TEZ DANIŞMANI: DR. ÖĞR. ÜYESİ ORHAN ERMETİN

Bu çalışmada büyükbaş hayvanlarda geleneksel kimliklendirme yöntemlerine alternatif olarak; yapay zekâ destekli otomatik bir yüz tanıma sistemi örneği geliştirilmiştir. Kullanılan modellerin eğitimi için oluşturulan veri setinde Yozgat iline bağlı bir işletmede bulunan sekiz mandaya ait yüz görüntüleri kullanılmıştır. Görüntüler farklı açılardan çekilerek ham veri seti oluşturulmuştur. Ham veri seti, literatürde geçerli, yaygın olarak kullanılan bazı veri artırım teknikleriyle artırılmış ve nihai olarak BUFFALO-22 ismiyle yeni bir veri seti oluşturulmuştur. Çalışmada oluşturulan BUFFALO-22 veri setinin eğitiminde geleneksel yöntemlerin yanı sıra modern yöntemler de işe koşularak sonuçları karşılaştırılmıştır. Geleneksel tarafta bazı ön işleme yöntemleri ile işlenen görsellerden yaygın kullanılan öznitelik çıkarım teknikleri (Gri Seviye Eş-Oluşum Matrisi ve Yerel İkili Desenler) kullanılarak istenilen öznitelikler çıkarılmıştır. Çıkarılan öznitelikler geleneksel sınıflandırıcı olarak Destek Vektör Makinesi kullanılarak sınıflandırılmıştır. Yapılan testlerde LBP-HSV modeli ile %87.7'lik bir test doğruluğu elde edilmiştir.

Diğer yandan modern yöntemler tarafında önceden eğitilmiş derin öğrenme modellerinden InceptionV3 ve nesne tanıma gibi görüntü sınıflandırma görevlerinde yaygın olarak önerilen derin öğrenme modeli YOLO'nun beşinci versiyonu olan YOLOv5 modeli kullanılmıştır. Deneysel sonuçlar hem InceptionV3 gibi önceden eğitilmiş CNN sınıflandırıcılarının hem de YOLOv5 gibi anlık tespit yaklaşımlarının hayvanlarda yüz tanımaya bağlı kimliklendirme görevlerinde başarılı bir şekilde kullanılabileceğini kanıtlamıştır. Sonuçlara göre InceptionV3 yaklaşımı yüz tespitinde %98.5'lik bir ortalama test doğruluğu elde etmiştir. YOLOv5 algoritmasının eğitimi sonucu 0.98'lik bir kesinlik, 0.99'luk bir hassasiyet ve 0.99'luk bir mAP değeri elde edilmiştir. Hem eğitim hem doğrulama hem de test doğruluk ölçütlerinin yanı sıra diğer ölçütler, bu çalışmada kullanılan modellerin hayvan kimliklendirme görevleri için rahatlıkla kullanılabileceği görüşünü desteklemiştir.

Yapılan çalışma sonucunda, hayvan kimliklendirmeye bağlı olarak verim denetimi, üreme, sağlık ve refahın takibi, davranış analizi gibi birçok araştırmanın kolaylaşmasının yolunun açabileceği de ön görülmektedir.

2023, xvi + 69 Sayfa

Anahtar Kelimeler: Hayvan kimliklendirme, Mandalarda yüz tanıma, Derin öğrenme, YOLOv5

ABSTRACT

MASTER THESIS

DEVELOPMENT OF WATER BUFFALO FACE RECOGNITION MODELS USING DEEP LEARNING AND TRADITIONAL MACHINE LEARNING TECHNIQUES

NİYAZİ HAYRULLAH TUVAY

**YOZGAT BOZOK UNIVERSITY
SCHOOL OF GRADUATE STUDIES
DEPARTMENT OF AGRICULTURAL SCIENCES**

SUPERVISOR: ASST. PROF. DR. ORHAN ERMETİN

In this study, an artificial intelligence-supported automatic facial recognition system has been developed as an alternative to traditional identification methods for large livestock. Facial images of eight buffalos from a facility in the Yozgat province were used in the dataset created to train the models. The images were captured from various angles to make the raw dataset. The raw dataset was augmented using some commonly used augmentation techniques in the literature, and ultimately, a new dataset named BUFFALO-22 was created.

In the study, the results were compared by employing both traditional and modern methods in the training of the BUFFALO-22 dataset. On the traditional side, common feature extraction techniques (Gray Level Co-occurrence Matrix and Local Binary Patterns) were utilized on images pre-processed with certain techniques to extract the desired features. The extracted features were classified using the Support Vector Machine as the traditional classifier. In the conducted tests, a test accuracy of 87.7% was achieved with the LBP-HSV model.

On the other hand, in the realm of modern techniques, the YOLOv5 model, the fifth version of the YOLO (You Only Look Once) deep learning model widely recommended for image classification tasks such as object recognition, was employed alongside pre-trained deep learning models like InceptionV3. Experimental results have demonstrated the successful utility of both pre-trained CNN classifiers like InceptionV3 and real-time detection approaches like YOLOv5 in animal identification tasks based on facial recognition. According to the results, the InceptionV3 approach achieved an average test accuracy of 98.5% in facial detection. Training the YOLOv5 algorithm resulted in a precision of 0.98, a recall of 0.99, and a mean average precision (mAP) value of 0.99. Furthermore, in addition to training, validation, and test accuracy metrics, other criteria have also supported the notion that the models employed in this study can be comfortably used for animal identification tasks.

The study suggests that animal identification may pave the way for the facilitation of various research areas such as performance monitoring, reproduction, health and welfare tracking, and behavior analysis.

2023, xvi + 69 Pages

Keywords: Animal identification, Facial recognition in buffalos, Deep learning, YOLOv5

İÇİNDEKİLER

Sayfa

TEZ ONAY SAYFASI	iii
TEZ BEYANI	iv
ÖNSÖZ.....	v
ÖZET.....	v
ABSTRACT	vi
İÇİNDEKİLER.....	x
TABLolar LİSTESİ	xiii
ŞEKİLLER LİSTESİ.....	xiv
KISALTMALAR LİSTESİ.....	xv
1. GİRİŞ	1
2. GENEL BİLGİLER.....	4
2.1. Manda Yetiştiriciliği ve Önemi	4
2.2. Hayvanları Tanıma ve Kimliklendirme Yöntemleri.....	7
2.3. Biyometrik Hayvan Tanımlama ve Önemi.....	10
2.3.1. Biyometrik Kimliklendirmede Kullanılan Yöntemler	11
2.3.1.1. Görsel Desenler.....	11
2.3.1.2. Burun Baskıları	11
2.3.1.3. İris Desenleri	12
2.3.1.4. Retina Desenleri.....	12
2.3.1.5. Yüz Tanıma.....	12
2.3.1.6. Kulak Damar Deseni.....	12
2.3.1.7. Isırık İzleri.....	13
2.3.1.8. DNA Analizi	13
2.3.1.9. Davranış veya Hareket	13
2.4. Makine Öğrenmesi	13
2.4.1. Makine Öğreniminde Öğrenme/Eğitim Yaklaşımları.....	15
2.4.2. Denetimli Makine Öğrenme Yaklaşımı	15
2.4.3. Denetimsiz Makine Öğrenme Yaklaşımı.....	16
2.4.4. Yarı Denetimli Makine Öğrenme Yaklaşımı	16
2.4.5. Takviyeli (Pekiştirmeli) Makine Öğrenme Yaklaşımı.....	17

	<u>Sayfa</u>
2.5. Geleneksel Makine Öğrenim Sınıflandırıcıları	17
2.5.1. Destek Vektör Makineleri.....	17
2.5.2. Karar Ağaçları.....	17
2.5.3. Rastgele Orman.....	18
2.5.4. K-En Yakın Komşu	18
2.5.5. Yapay Sinir Ağları (Artificial Neural Network).....	18
2.6. Derin Öğrenme	19
2.6.1. Evrişimsel Sinir Ağları (CNN)	20
2.6.2. YOLO Gerçek Zamanlı Nesne Algılama Yaklaşımı	20
2.7. Makine Öğrenimine Dayalı Hayvanları Tanıma Çalışmaları.....	25
3. MATERYAL VE YÖNTEM	31
3.1. Materyal.....	31
3.2. Yöntem	32
3.2.1. Veri Artırma.....	32
3.3. Geleneksel Görüntü Sınıflama Analizi.....	34
3.3.1. İstatistiksel Öznitelik Çıkarımı	34
3.3.1.1. Gri Seviye Eş-Oluşum Matrisi (GLCM) Öznitelik Çıkarımı.....	34
3.3.1.2. Yerel İkili Örüntüler (LBP) Öznitelik Çıkarımı	35
3.3.2. Renk Dönüşümleri	36
3.3.3. Geleneksel Sınıflandırıcılar	36
3.3.3.1. DVM (Destek Vektör Makineleri).....	36
3.3.3.2. Yapay Sinir Ağları (YSA).....	36
3.3.4. Önerilen Geleneksel Makine Öğrenme Modeli	37
3.4. Derin Öğrenme Analizi	38
3.4.1. Evrişimsel Sinir Ağları (CNN)	38
3.4.2. Transfer Öğrenimi.....	38
3.4.3. InceptionV3	38
3.4.4. YOLOv5	39
3.4.5. Önerilen Derin Öğrenme Modeli.....	39
3.5. Performans Değerlendirme.....	39
3.5.1. Doğruluk	40
3.5.2. Kesinlik.....	40

	<u>Sayfa</u>
3.5.3. Hassasiyet	40
3.5.4. F1-Skor	40
4. BULGULAR VE TARTIŞMA	41
4.1. Geleneksel Makine Öğrenimine Dayalı Yüz Tanıma Bulguları	41
4.2. Derin Öğrenme Analiz Bulguları	44
4.2.1. InceptionV3	44
4.2.2. YOLOv5	48
4.3. Tartışma.....	53
5. SONUÇ VE ÖNERİLER	56
6. KAYNAKLAR.....	58

TABLÖLER LİSTESİ

<u>Tablo</u>	<u>Sayfa</u>
Tablo 2.1. Manda ve diğer çiftlik hayvanlarının süt içeriklerinin (%) karşılaştırılması	5
Tablo 2.2. Manda ve sığır etinin karşılaştırılması (100 gr)	6
Tablo 2.3. Manda yetiştiriciliğinin kıtalara göre dağılışı.	6
Tablo 2.4. Manda yetiştiriciliğinin ülkelere göre dağılışı	7
Tablo 2.5. YOLO (v3, v4, v5s ve Tiny) modellerinin özellikleri.....	21
Tablo 3.1. Ham veri setine ilişkin istatistikler.....	31
Tablo 3.2. Veri artırımı sonrası veri istatistikleri	33
Tablo 4.1. Eğitim, doğrulama ve test grupları.....	41
Tablo 4.2. Öznitelik seti verileri.....	42
Tablo 4.3. Doğrulama doğruluk oranları (%)	42
Tablo 4.4. Test doğruluk oranları (%)	43
Tablo 4.5. Modellerin diğer ölçütler dikkate alınarak karşılaştırmalı performansları.....	44
Tablo 4.6. InceptionV3'ün diğer ölçütler dikkate alınarak performans sonuçları.....	47
Tablo 4.7. Benzer yaklaşımların kullanıldığı ilgili çalışmaların özeti	55

ŞEKİLLER LİSTESİ

<u>Şekil</u>	<u>Sayfa</u>
Şekil 2.3. YOLOv5 mimarisinin genel yapısı.....	21
Şekil 2.4. YOLO modeli çalışma prensibi	22
Şekil 2.5. YOLOv5 varyantları çalışma hızları.....	23
Şekil 2.6. Önerilen yöntem aşamaları	24
Şekil 2.7. Sınıflandırılan hayvanlar.....	26
Şekil 2.8. Kafes arkasında algılanan pandalar	27
Şekil 2.9. Veritabanındaki burun görüntülerinden bazıları.....	28
Şekil 2.10. Başarılı şekilde tanınan farklı sınıflara ait sığır yüzleri	28
Şekil 2.11. Koyun acı çekme algılaması (McLeenan vd., 2019.....	29
Şekil 3.1. Mandaların görüntüsünü alma çalışması	31
Şekil 3.2. Artırılmış görüntüler	33
Şekil 3.3. BUFFALO-22 veri seti kullanılarak eğitilen model mimarisinin aşamaları	37
Şekil 4.1. GLCM-HSV ve LBP-HSV öznitelik seti üzerinde eğitilen modeller için karışıklık matrisleri, solda GLCM-HSV modeli ve sağda LBP-HSV modeli	43
Şekil 4.2. InceptionV3'ün 20 döngü için eğitim süreç grafiği.....	45
Şekil 4.4. InceptionV3 modeli 20 döngü (epoch) için eğitilmiş ve her döngüden sonra eğitim-doğrulama kayıp değerleri	46
Şekil 4.5. InceptionV3 modeli için karışıklık (hata) matrisi.....	47
Şekil 4.6. İlk 10 ve son 10 epoch verileri.....	49
Şekil 4.7. Soldan sağa sırasıyla kesinlik (precision), hassasiyet (recall) ve mAP grafikleri	50
Şekil 4.8. YOLOv5 modelinin manda yüz görüntüleri üzerinde anlık tespit durumları.....	51
Şekil 4.9. YOLOv5 modelinin 5 numaralı manda yüz görüntüleri üzerinde anlık tespit durumları	52
Şekil 4.10. YOLOv5 modeline ait karışıklık matrisi	53

SİMGELER VE KISALTMALAR LİSTESİ

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Kısaltmalar Açıklamalar

AI	: Yapay Zekâ (Artificial Intelligence)
RFID	: Radyo Frekansı ile Tanımlama (Radio Frequency Identification)
DNA	: Deoksiribo Nükleik Asit
PLF	: Hassas Hayvancılık (Precision Livestock Farming)
ML	: Makine Öğrenimi
SVM	: Destek Vektör Makineleri (Support Vector Machines)
RF	: Rastgele Orman
K-NN	: K-En Yakın Komşu (K-Nearest Neighbors)
DL	: Derin Öğrenme (Deep Learning)
YSA	: Yapay Sinir Ağları (Artificial Neural Network- ANN)
DNN	: Derin Sinir Ağları (Deep Neural Networks)
CNN	: Evrişimsel Sinir Ağları (Convolutional Neural Networks)
DCNN	: Çift Derin Evrişimli Sinir Ağı
R-CNN	: Bölgesel Tabanlı Evrişimsel Sinir Ağları
Faster R-CNN	: Daha Hızlı Bölgesel Evrişimsel Sinir Ağları
Mask R-CNN	: Maske Daha Hızlı Bölgesel Evrişimsel Sinir Ağları
DCNN	: Derin Konvolüsyonel Sinir Ağları (Deep Convolutional Neural Networks)
YOLO	: Gerçek Zamanlı Nesne Algılama Yaklaşımı (You Only Look Once)
SSD	: Tek Aşamalı Dedektör (Single Shot Detector)
GLCM	: Gri Seviye Eş-Oluşum Matrisi (Gray Level Co-Occurrence Matrix)
LBP	: Yerel İkili Örüntüler (Local Binary Patterns)
SVM	: Destek Vektör Makineleri (Support Vector Machines)

Kısaltmalar Açıklamalar

AP	: Ortalama Kesinlik (Average Precision)
mAP	: Ortalama Kesinliklerin Ortalaması (Mean Average Precisions)
TP	: Doğru Pozitifler
TN	: Doğru Negatifler
FP	: Yanlış Pozitifler
FN	: Yanlış Negatifler
PE	: İşlem Elemanları (Processing Element)
LBP	: Yerel İkili Örüntüler (Local Binary Patterns)

1. GİRİŞ

Günümüzde tarım, hızla artan nüfus artışı, küresel ısınma ve tarım arazilerinin kirlenmesi gibi büyük zorluklarla karşı karşıyadır. Önümüzdeki 50 yılda tarım ürünlerine karşı talebin karşılanabilmesi için üretimin %70 oranında artırılması gerekmektedir. Ancak sınırlı kaynaklar, iklim değişiklikleri ve diğer kısa vadeli ve bölgesel tehditler nedeniyle bu hedef tehlike altındadır (Bayramoğlu vd., 2018).

Tarımsal üretimin sürdürülebilirliği, doğal kaynakların etkili ve verimli kullanılmasının yanı sıra üretimde bulunan kişilerin sosyo-ekonomik açıdan geliştirilmesine yardımcı olabilecek tekniklerin uygulanması zorunluluğunu içermektedir (Kaya vd., 2010). Bu gerekliliklerin karşılanabilmesi için uygulanan tarım sisteminin eksikliklerinin giderilmesi ve yeni, etkili teknolojilerin geliştirilmesi gerekmektedir (Altay ve Turhal, 2011; Demir, 2013). Modern tarım teknikleri, tarım sektöründe üretimin artırılması, iş veriminin yükseltilmesi, işin kolaylaştırılması, maliyetlerin düşürülmesi, işletmelerin modernleştirilmesi, yeni istihdam alanlarının açılması ve tarım nüfusunun sosyo-ekonomik açıdan geliştirilmesi açısından büyük öneme sahiptir (Kirmikil ve Ertaş, 2020).

Görüntü işleme ve bilgisayarlı görme uygulamalarının ekipman maliyetlerinin düşmesi ve hesaplama yeteneklerinin artması, nitelikli gıda değerlendirme yöntemlerine olan ilginin artmasının yanı sıra yapay zekâ kullanımına yönelik ilgiyi de artırmıştır (Mahajan ve Sardana, 2015). Görüntü işleme teknikleri, model tanıma algoritmaları ve otomatik sınıflandırma araçları ile birleştirilerek gıda kalitesinin analiz edilmesini mümkün kılmıştır (Patrício ve Rieder, 2018). Bu gelişmeler, tarım sektöründe akıllı tarım uygulamalarına olan ilgiyi artırmıştır.

Yapay Zekâ ve Endüstri 4.0 teknolojilerinin tarım alanında kullanılmasıyla, Akıllı Tarım veya Tarım 4.0 olarak adlandırılan teknoloji, gelişmiş ülkelerde yaygınlaşmış ve başarıyla uygulanmıştır (Uzun vd., 2018). Gelişmiş teknoloji ve modern bilişim yöntemlerinin bir araya getirilmesiyle tarım sektöründe etkili ve verimli bir şekilde kullanılmasına akıllı tarım denmektedir (Wolfert vd., 2017; Demir vd., 2021).

Hayvancılık, tarımsal olarak gelişmiş birçok ülkede tarımın büyük bir bölümünü oluşturmaktadır. Artan nüfusun hayvansal ürünlere olan talebini karşılamak ve insanların beslenmesindeki değişikliklere cevap verebilmek için beslenme alışkanlıkları, hayvansal üretim ve hayvan refahının iyileştirilmesine ihtiyaç vardır (Liaghat ve Balasundram, 2010).

Hayvancılık, küçük çaplı ve geçim amaçlı tarım faaliyetlerinden entansif yetiştiriciliğe doğru ilerlemektedir. Büyük çiftliklerde ve geniş meralara dayalı üretim sistemlerinde karşılaşılan işgücü eksikliği, gerçek zamanlı izleme zorlukları ve yüksek yönetim maliyetleri gibi faktörler, ciddi zorluklar oluşturmaktadır. Bu durum ise, hayvansal tarım sistemlerindeki bu zorlukların üstesinden gelmek için kesin ve uygun maliyetli teknoloji yöntemlerini zorunlu kılmaktadır (Xu vd., 2020). Nispeten yeni bir teknoloji olmasına karşın, Yapay Zekâ (AI)'nın bu zorlukların çözümünde etkili olabileceği görülmektedir. Nitekim teknolojinin kullanımı ile bu sorunların aşılabacağı fikri öne çıkmakta ve özellikle önümüzdeki 50 yılda insanlığın yeni bir evrim aşamasına girerek yapay zekâ ile birleşeceğini öngörmektedir (Buchanan, 2006).

Hayvancılık işletmelerinde, yoğunlaşan kullanım alanlarıyla yapay zekâ teknolojisinin, hayvan sağlığı ve refahını artırmak için akıllı çiftçilik uygulamalarında önemli bir rol oynadığı belirtilmektedir. Yapay zekâ, herhangi bir bilgisayar sisteminden insanla eşit veya daha iyi performans gösterme potansiyeline sahip bir ana bilgisayar olarak tüm sektörlerde benimsenmiştir. Sağlık, endüstri, ticaret, eğitim, turizm, hayvan gözlemi ve korunması gibi farklı alanlarda çeşitli kuruluşlar tarafından kullanılan yapay zekâ, günümüzde hayvan gözetimindeki temel ihtiyaçları karşılamada özellikle insan gücü eksikliği ve iş kısıtlamaları nedeniyle önemli bir rol oynamaktadır (Kumar ve Singh, 2014; Bao ve Xie, 2022).

Dünyada sığırlardan sonra en fazla süt üreten hayvan olan mandalar konusunda birçok genetik, besleme ve yetiştirme araştırmaları yapılmaktadır. Ancak entansif şartlarda manda yetiştiriciliği ve PLF teknolojilerine (hassas tarım teknolojileri) uyum konusundaki araştırmalar çok azdır. Mandaların üreme problemleri (gizli kızgınlık, döl tutmama vb.), ısı stresi ve süt sağımı konularında sürü yönetim teknolojilerinden daha fazla yararlanmaları ve bu konularda araştırma yapılması ihtiyacı vardır.

Her şeyden önce mandaların agresif yapılarından dolayı yaklaşmak, kulak küpelerini okumak veya müdahale etmek çok güçtür. Özellikle yabancı bir kişinin yaklaşması ve müdahale etmesi yaralanmalarına kadar sebep olacak sonuçlar doğurur. Hayvanların ürkme, saldırma veya sütü indirmeme gibi davranışlarını önlemek için doğal davranışlarını sergileyeceği barınak tipleri ve insandan mümkün olduğunca uzak bir yaşam alanı oluşturma ihtiyacı vardır. Mevcutta kullanılan kulak küpelerinin okunamaması, düşmesi ve takma esnasındaki saldırgan davranışları azaltmak amacı ile yapay zekâ teknikleri ile tanımlanması çok önemlidir. Yüz tanıma şeklinde belirlenen hayvanlara yaklaşımadan

kimlik bilgileri (pedigri, st ve reme bilgileri vb.) ok kolay tespit edilebilir ve gerekli mdahaleler yapılabilir. Manda yetiřtiriciliğinde derin ğrenme ve geleneksel makine ğrenme teknikleri kullanılarak manda yz tanıma modellerinin geliřtirilmesi ile PLF uygulamaları iin zemin oluřturulmuř olacaktır (Ermetin, 2021).

Geliřen teknoloji ile birlikte modern hayvansal retim uygulamalarının yetiřtiriciliğın her alanında hassas ve doğru prensiplerin uygulanmasına imkan saėlaması, ynetim sistemini iyileřtirmesi ve iřletme kayıplarını azaltması gibi stnlklerinden dolayı kullanılması birok fayda saėlayacaktır. alıřmamızda gerek mizacı ve gerekse de yetiřtiricilik řekliyle hassas tarım teknikleri uygulanmayan manda yetiřtiriciliğinde, biyometrik tanıma yntemlerinden “yz tanıma” yntemini derin ğrenme ve geleneksel makine ğrenme teknikleri kullanılarak ve manda yz tanıma modelleri geliřtirilerek literatre kazandırılması hedeflenmiřtir.

2. GENEL BİLGİLER

2.1. Manda Yetiştiriciliği ve Önemi

Dünya nüfusu sürekli artmakta, ancak buna paralel olarak bir beslenme yetersizliği sorunu ortaya çıkmaktadır. Küresel ısınma, salgın hastalıklar ve diğer etmenler dolayısıyla tarım ürünlerinde sürekli bir azalma yaşanmaktadır (Aslan, 2004). Bunun bir sonucu olarak, sağlıklı gıdaya erişim ve gıda güvenliği sorunu ortaya çıkmaktadır (Gürel ve Aslan, 2019). İnsanların sağlıklı bir yaşam sürmelerinin ilk şartı, yeterli ve dengeli beslenmedir (Baysal, 1996). Bu sebeplerden ötürü, ucuz, organik, çevre dostu ve kolay elde edilebilir gıdalara artan bir talep söz konusudur (Demiryürek, 2004; Hekimoğlu ve Altındeğer, 2006). Yukarıda bilgiler ışığında bakıldığında, manda ve manda ürünleri önemli bir alternatiftir (Satılmış, 2022). İçinde bulunduğumuz zaman dilimine kadar diğer çiftlik hayvanlarına oranla daha az önem verilen mandanın değeri, çeşitli özellikleri ve verimleri nedeniyle son yıllarda artmıştır (Ermetin, 2020; Satılmış, 2022). Farklı çevresel faktörlere kolaylıkla uyum sağlayabilen ve düşük kalitedeki ve ucuz kaba yemleri değerlendirebilen manda, hastalıklara da sığırdan daha dayanıklıdır (Kul vd., 2018). Mandaların, ucuz ve kalitesiz kaba yemleri et ve süte dönüştürebilmeleri nedeniyle yetiştirme ve yem giderleri oldukça düşüktür (Atasever ve Erdem, 2008).

Mandalar, geniş getiren bir sığır türü olup çift tırnaklı hayvanlar ailesine aittir. Mandalar günümüzde et, deri, süt, et ürünleri, boynuz ve çeki gücünden yararlanmak amacıyla kullanılmaktadır (Atasever ve Erdem, 2008). Mandalar sığırlarla kıyaslandığında daha geç gelişebilmesine karşın ömrü 30 yıla kadar çıkabilmektedir. Mandaların gelişimi altı yaşına kadar sürmektedir. Cinsel olgunluğa sığırlardan daha geç ulaşırlar. Manda düvesi 13-14 aylık yaşta cinsel olgunluğa ulaşmaktadır ve düveler 22-24 aylık yaşta tohumlanabilirler. Erkek mandalar 20-21 aylıktan itibaren 5-6 yaşlarına kadar amızlık boğa olarak kullanılabilir (Ermetin, 2020).

Mandaların ineklerinde kızgınlık sığırlardaki kadar belirgin değildir ve bu dönem daha sakin seyreder. Manda ineklerinde gebelik süresi iklim, ırk ve diğer çevresel faktörlere göre değişmekle beraber yaklaşık olarak 299-346 gün sürmektedir. Ortalama olarak 315-319 gündür (Kul vd., 2022). Mandalarda doğum süresi yaklaşık olarak 5 saat sürmektedir. Doğum genellikle gece veya sabaha karşı gibi günün sakin saatlerinde gerçekleşir.

Mandalar doğumu genellikle yardıma ihtiyaç duymadan gerçekleştirirler ve genellikle tekiz yavru doğururlar (Ermetin, 2020).

Ergin mandalarda deri kalınlığı genellikle 6,0-7,6 mm olmakla beraber, sığır derisinden daha kalındır. Bununla beraber kıl örtüleri ve deri altı ter bezleri sığırlara göre %10 daha azdır. Kıl örtülerinin ve ter bezlerinin azlığı nedeniyle özellikle sıcak yaz aylarında vücut ısılarını ayarlayamazlar ve huzursuz olurlar. Bu yüzden suda yüzmeye veya bataklığa girmeğe ihtiyaç duyarlar. Aynı sebepten ötürü, soğuğa karşı dirençleri sığırdan daha azdır (Yılmaz, 2013; Ermetin, 2020).

Et, süt, deri ve işgücü olarak yararlanılan mandalar, özellikle gelir düzeyi düşük ülkeler için önemli bir çiftlik hayvanıdır. Ülkemizdeki mandaların süt verimleri çevresel şartlara göre farklılık göstermekle beraber ortalama süt verimleri 1000 kg/yıl ve laktasyon süreleri ise ortalama 250 gündür (Şahin ve Ulutaş, 2014; Ermetin, 2020; Kul, 2020).

Manda sütündeki besin maddesi içeriği inek sütünden daha yüksektir. Ayrıca manda sütü inek sütüne oranla daha az su ve daha fazla kuru madde, yağ ve protein içermekle beraber, toplam kuru madde miktarı inek sütüne oranla daha fazla olduğu için tereyağı, krema ve peynir gibi süt ürünlerinin verimini de artırmaktadır (Soysal, 2013).

İnek sütünün her bir 100 gramından 70 kalori edilmesine karşılık, manda sütünün 100 gramından 100 kalori enerji elde edilmektedir. Manda sütünden elde edilen yağ miktarı, inek sütünden elde edilen yağ miktarından daha fazladır. Manda sütündeki kolesterol miktarı daha az olmasına karşılık E vitamini (tokoferol) miktarı daha yüksektir. Manda sütü beyaz renkli olması, yüksek miktarda yağ içermesi ve lezzeti sebebiyle tüketicilerin tercih ettiği bir süttür (Ermetin, 2020).

Manda sütü ile diğer çiftlik hayvanlarının sütlerinin bileşenlerinin karşılaştırılması Tablo 2.1’de verilmiştir.

Tablo 2.1. Manda ve diğer çiftlik hayvanlarının süt içeriklerinin (%) karşılaştırılması (Oysun, 1987; Demirci vd., 1991; Ermetin, 2017)

Tür	Su	Kuru Madde	Protein	Yağ	Laktoz	Mineral Madde
Manda	82,0	17,7	4,15	7,85	4,80	0,77
İnek	87,5	12,4	3,40	3,65	4,65	0,75
Koyun	82,9	17,2	5,40	6,25	4,55	0,88
Keçi	87,1	13,0	3,70	4,10	4,45	0,80

Et olarak ele alındığında ise manda eti, insanların tüketebileceği en sağlıklı kırmızı et grubundan biridir. Manda etinin kolesterol ve kalori içeriği düşüktür. İntramuskuler yağ tabasının daha az olması ve daha pigmentasyon sebebiyle manda eti koyu kırmızı renktedir (Ermetin, 2020).

Manda ve sığır et özelliklerinin karşılaştırılması Tablo 2.2’de verilmiştir.

Tablo 2.2. Manda ve sığır etinin karşılaştırılması (100 gr) (Soysal, 2009; Ermetin, 2017)

Bileşenler	Manda Eti	Sığır Eti
Protein (gr)	26,8	24
Kalori (kcal)	131	289
Kolesterol (mg)	61	90
Yağ (gr)	1,8	21
Vitamin (mg)	21	18,5
Mineral (mg)	641,8	584

Manda yetiştiriciliği, dünyada en çok Asya kıtasında yaygın olmakta olup, sırasıyla Amerika ve Afrika kıtaları yetiştiriciliğin yaygın olduğu kıtalardır (Tablo 2.3).

Tablo 2.3. Manda yetiştiriciliğinin kıtalara göre dağılışı (FAO, 2022).

KITALAR	1970	1980	1990	2000	2010	2020
Asya	104.474.437	118.085.115	143.302.442	159.383.735	188.634.118	199.535.945
Amerika	124.400	503.000	1.405.162	1.108.426	1.191.132	1.848.137
Afrika	2.009.025	2.346.608	2.897.492	3.530.025	3.818.261	1.671.403
Avrupa	654.382	558.767	578.919	232.499	390.682	477.293
Okyanusya	-	-	-	130	150	166
Toplam	107.262.244	121.493.490	148.184.015	164.254.815	194.034.343	203.532.944

Asya kıtası, manda yetiştiriciliği konusunda büyük bir öneme sahip olmasına rağmen, bu faaliyetin kıtanın geneline eşit bir şekilde yayılmadığı gözlemlenmektedir. Manda yetiştiriciliği Asya’nın güneydoğu bölgelerinde yoğunlaşmış durumdadır ve özellikle Hindistan, Pakistan ve Çin bu faaliyette öne çıkan ülkelerdir. Hindistan, 2020 yılı itibarıyla 109.719.011 baş ile bu alandaki lider konumda bulunmaktadır. Pakistan, 41.191.000 baş ile ikinci sırada ve Çin ise 27.223.427 baş ile üçüncü sırada yer almaktadır. Türkiye ise 2020 yılında dünyada 20. sırada yer alarak, manda yetiştiriciliğinde Avrupa ülkelerinde İtalya’dan sonra en fazla manda sayısına sahiptir (Tablo 2.4).

Tablo 2.4. Manda yetiştiriciliğinin ülkelere göre dağılışı (FAO, 2022).

	ÜLKELER	1970	1980	1990	2000	2010	2020
1	Hindistan	56.118.000	66.070.000	80.570.000	93.831.000	107.375.000	109.719.011
2	Pakistan	9.345.000	11.547.000	17.373.008	22.669.000	29.413.000	41.191.000
3	Çin	15.713.063	18.439.752	21.421.975	22.595.017	29.464.034	27.223.427
4	Nepal	1.020.000	2.500.000	3.012.565	3.525.952	4.836.984	5..257.591
5	Myanmar (Burma)	1.540.718	1.901.000	2.061.000	2.441.240	2.977.150	4.125.140
6	Filipinler	4.431.500	2.870.270	2.764.950	3.024.403	3.270.400	2.865.715
7	Vietnam	2.270.700	2.313.000	2.854.100	2.897.220	2.877.000	2.332.754
8	Mısır	2.009.000	2.346.583	2.897.467	3.530.000	3.818.236	1.671.378
9	Brezilya	118.000	495.000	1.397.097	1.102.551	1.184.511	1.502.482
10	Bangladeş	835.000	475.000	772.000	890.000	1.349.000	1.493.000
11	Laos	770.000	862.300	1.071.757	1.028.000	1.189.000	1.234.000
12	Endonezya	2.885.000	2.457.000	3.335.079	2.405.277	1.999.604	1.179.342
13	Tayland	5.734.500	5.650.794	5.094.270	1.711.573	1.622.646	923.533
14	Kamboçya	910.000	375.000	736.000	693.631	702.074	639.922
15	İtalya	48.600	88.900	112.400	182.000	365.086	407.030
16	Kolombiya	-	-	-	-	-	338.567
17	Sri Lanka	735.708	843.100	958.100	304.500	422.650	323.000
18	Irak	288.000	170.000	150.000	115.000	295.000	233.453
19	İran	240.000	240.000	440.000	490.600	195.000	171.156
20	Türkiye	1.178.000	1.040.000	429.000	165.000	87.207	192.489

2.2. Hayvanları Tanıma ve Kimliklendirme Yöntemleri

Bir damızlık işletmede yüksek düzeyde verim almak ve bu verimleri her generasyonda ya da her yıl artırabilmek için öncelikle sürüdeki hayvanları iyi tanımak gerekmektedir. Bu nedenle düzenli verim kontrolleri yapılmalı ve kayıtları tutulmalıdır. Verim kayıtları düzenli olarak defterlere ya da bilgisayara işlenir. Kayıt tutmak sadece yetiştiricinin hayvanları hakkında bilgi sahibi olmasını sağlamakla kalmaz aynı zamanda işletmenin gelecekle ilgili hedeflerini koymasına da yardımcı olur (Akman, 1997).

Çiftlik hayvanlarının kimliklerinin tanımlanması, doğrulanması ve izlenmesi, hayvan hareketlerinin kontrol altına alınması ve hastalıkların önlenmesi açısından büyük öneme sahiptir. Ayrıca, hayvansal ürünlerin üretim kalitesinin ve kaynağının bilinmesi, dünya ekonomisi ve insan sağlığı için gereklidir (Hogeveen vd., 1991). Süt sığırcılığı, giderek

daha entansif bir yapı kazanmış ve bu da sürü yönetimini daha karmaşık hale getirmiştir. Çünkü yetiştiricilerin daha doğru kararlar alabilmesi için daha fazla veriye ihtiyaçları vardır. Bu veriler, sürü sahipleri veya yetiştirici birlikleri gibi üçüncü taraflar tarafından manuel olarak toplanabilir veya otomatik sistemler aracılığıyla kaydedilebilir. Bu bakımdan bilgi ve elektronik çağ, süt sığırcılığı sektörü için yeni teknolojiler ve fırsatlar sunmaktadır. Ancak, bu yeniliklere uyum sağlamak çaba gerektiren bir süreçtir. Tüm zorluklara karşın yeniliklerin benimsenmesi süt sığırcılığı sektörüne önemli avantajlar sağlayabilir (Tomaszewski, 1993).

Geçmişten günümüze hayvan kimliklendirmede farklı yöntemler kullanılmış ve zamanla bunlardan kimilerinin hayvan refahına zarar verdiği ve zamanla deformasyonlara uğradığı, kaybolduğu, özelliğini yitirdiği gibi sıkıntılarla karşı karşıya kalındığı bilinmektedir (Mori vd., 2000; Çelikyürek ve Karakus, 2017). Hayvanları geleneksel yöntemler ile işaretlemek, hayvanların davranışlarını olumsuz yönde etkileyebilir ve zararlı sonuçlar doğurabilir. Bu durum araştırma sonuçlarında hatalı veriler elde edilmesine neden olabilir (Bugge vd., 2011; Lu vd., 2014).

Kimliklendirme yöntemlerinin pek çok türü bulunmakta ve tercih edilen yöntemin belirli özelliklere sahip olması gerekmektedir. Bu özellikler arasında amaca uygunluk, kolay uygulanabilirlik, düşük maliyet, pratiklik ve sürdürülebilirlik bulunmaktadır. Elektronik kimliklendirme etiketleri, transponderlar ve radyo frekanslı enjekte edilebilir transponderlar gibi elektronik etiketler, çiftlik hayvanlarının kimliklendirilmesinde önemli bir rol oynamaktadır. Bu teknolojiler, pet hayvanlardan laboratuvar hayvanlarına ve hatta yabani hayvanlara kadar birçok farklı türün kimliklendirilmesinde kullanılmaktadır. Ayrıca, sığırların veya koyunların işaretlenmesinde ve kaçakçılığı veya sahteciliği önleme amacıyla kulak küpeleri veya bolus tipi transponderlar gibi çeşitli elektronik kimliklendirme yöntemleri kullanılmaktadır (Çelikyürek vd., 2018). Ancak, çiftlik hayvanlarında kullanılan klasik ve modern kimliklendirme yöntemlerinin hem avantajları hem de dezavantajları vardır. Bu yöntemlerin avantajları arasında hayvanların izlenmesi ve kayıt altına alınmasının kolaylığı, hızlı tanımlama, verilerin daha iyi saklanması ve kullanılabilirliği gibi faktörler bulunmaktadır. Dezavantajları için ise kullanılan materyallerin zamanla bozulabilir, düşebilir veya çıkarılabilir olması örnek verilebilir. Bu, kimliklendirme sürecini zorlaştırabilir ve veri kaybına yol açabilir. Ayrıca, bazı kimliklendirme yöntemleri hayvanlara acı verebilir, enfeksiyon riskini artırabilir ve hayvanların morfolojik özelliklerinin değişmesine neden olabilir. Bunun yanı sıra,

kimliklendirme işlemini gerçekleştiren personelin yeterli tecrübeye sahip olmaması da sorunlara yol açabilir (Johnston ve Edwards., 1996). Sonuç olarak, bazı kimliklendirme yöntemleri üretim sürecinin son aşamasına kadar sürdürülemeyebilir. Bu nedenle, kimliklendirme yöntemlerinin seçiminde dikkatli bir değerlendirme ve uygun yöntemin seçilmesi önemlidir, çünkü bu hayvanların izlenmesi ve yönetilmesinde kritik bir rol oynar.

Hayvan kimliklendirmesi konusunda son zamanlarda metal küpeler, esnek plastik küpeler ve deri altına enjekte edilen pasif RFID (Radyo Frekansı Tanımlama) etiketler ve rumen bolusları gibi yöntemler yoğun bir şekilde kullanılmaktadır. Ancak, bu elektronik kimliklendirme yöntemlerinin uygulanması uzmanlık gerektirebilir ve bazen hayvanların sakatlanmasına veya hatta ölümlerine neden olabilecek ciddi kazalara yol açabilir (Bugge vd., 2011; Lu vd., 2014). Bu gibi sorunları azaltmak amacıyla, yeni arayışlar ve çalışmalar hayvan kimliklendirmesi alanında yürütülmektedir. Bu bağlamda, hayvanlarda geleneksel kimliklendirme yöntemlerinin yanı sıra biyometrik kimliklendirme yöntemlerinin de kullanılmaya başlandığını gözlemlemekteyiz. Biyometrik kimliklendirme, hayvanların benzersiz fiziksel özelliklerini kullanarak tanınmasını sağlar. Bu tür kimliklendirme yöntemleri, örneğin hayvanın yüzünün veya vücut özelliklerinin taranması ve dijital olarak kaydedilmesi yoluyla gerçekleştirilebilir. Bu yaklaşım, elektronik etiketler veya deri altına enjekte edilen cihazlarla ilgili sakatlanma veya ölüm riskini azaltabilir. Biyometrik kimliklendirme yöntemleri, hayvanlar arasında benzersiz özelliklerin bulunmasına dayandığı için daha güvenilir ve güvenlik açısından daha etkilidir. Ayrıca, bu yöntemlerin kullanımı ile hayvan vücudunda delinme, kesilme gibi işlemler olmayacağı için hayvan refahına daha uygundur. Ancak, biyometrik kimliklendirme yöntemlerinin yaygınlaşması ve uygulanabilirliği konusunda daha fazla çalışma ve standartlaştırma gerekebilir. Hayvan kimliklendirme alanında yeni teknolojiler ve yaklaşımlar geliştirilmeye devam etmektedir ve bu, hayvanların izlenmesi ve yönetilmesi konusundaki sorunları azaltmada önemli bir adım olabilir (Awad, 2016).

Çiftlik hayvanlarının kimliklendirilmesi sürecinde, tercih edilen yöntemin belirli özelliklere sahip olması gerekmektedir. Bu özellikler, çevresel sürdürülebilirlik, dayanıklılık, kolay uygulanabilirlik, maliyet etkinliği, uzun süreli kullanım, biyomorfolojik ve biyomoleküler özellikler gibi faktörleri içermelidir (Yalçın ve Baykan, 2013). Elektronik ve biyometrik kimliklendirme yöntemleri, hayvanların tanınması, geçmiş performans bilgilerinin kaydedilmesi, çağırılması ve yeni verilerin toplanması gibi süreçleri kolaylaştırmakta ve geleneksel kimliklendirme yöntemlerine kıyasla bir dizi avantaj

sunmaktadır. Bu yeni yöntemler, elektronik ekipmanlar ve yazılımlarla entegre edilebilen ve bu yazılımlara kolayca uyum sağlayabilen kimliklendirme yöntemleridir (Çelikyürek ve Karakuş, 2017). Son dönemde biyometrik kimliklendirme yöntemleri, mevcut kimliklendirme uygulamalarını desteklemek amacıyla kullanılmaya başlanmıştır. Bu yaklaşım, mevcut kimliklendirme yöntemlerinin karşılaştığı sorunları çözmeye, hayvan hırsızlıklarını önlemeye ve kayıtların daha güvenilir bir şekilde takip edilmesine yardımcı olmaktadır. Bu nedenle biyometrik kimliklendirme, tercih edilen bir yöntem olmaktadır. Bu gelişmeler, hayvan kimliklendirme süreçlerinin daha etkili ve güvenilir hale getirilmesine katkıda bulunmaktadır ve hayvancılık sektörünün daha sürdürülebilir hale gelmesine yardımcı olabilir (Awad, 2016).

2.3. Biyometrik Hayvan Tanımlama ve Önemi

Hayvan tanımlama için kullanılan mekanik ve elektronik yöntem ve cihazların farklı hayvanlara da uygulanabilir olması, sensörlerin bozulması, sahtecilik ve çalınma gibi durumları önleyemediğinden dolayı çok güvenli bir takip ve tanıma sistemi olarak değerlendirilmemektedir (Marchant, 2002; Kumar, vd., 2018). Geleneksel kimliklendirme yöntemlerinden kaynaklanan bu gibi sorunları aşmak amacıyla biyometrik kimliklendirme yöntemleri son yıllarda kullanılmaya başlanmıştır (Çelikyürek ve Karakuş, 2017).

Biyometri, bir bireyin fiziksel ya da davranışsal benzersizliğini ölçen ve mevcut kayıtlarla karşılaştırarak tanımlama işlemi yapan otomatik bir sistemdir. Bu yöntem sayesinde, hayvanların kalıtsal ve fiziksel özellikleri ile davranış belirtilerine göre tanımlamalar yapılabilmektedir. Biyometrik kimliklendirme ve tanımlamada hayvanın kimliği benzersizdir, tekrar tekrar kullanılabilir ve zamanla değişime uğramaz (Çelikyürek ve Karakuş, 2017).

Biyometrik yöntemlerde, geleneksel yöntemlerde karşılaşılan sorunlar bulunmamakta olup, bu yöntemlerin hayvan refahına hiçbir olumsuz etkisi yoktur ve hayvanlarda kesinlikle bir acı veya ağrıya sebep olmazlar. Ayrıca geleneksel yöntemlerde yaşanan hayvanın tekrar yakalanması ve kayıt altına alınması gibi durumlar ortadan kalkmaktadır (Bugge vd., 2011; Çelikyürek ve Karakuş, 2017).

Biyometrik yöntemler, kalıcı ve bozulmayan bir yapıda olmalıdır. Uygulandığı hayvana zarar vermemeli, kolay uygulanabilir olmalı ve elde edilen verilere hızlı bir şekilde erişime imkan sağlamalıdır (Aydın, 2007). Bununla birlikte hayvanlarda strese sebep olmayacak,

sürü içerisindeki hayvanların doğal davranışlarına etki etmeyecek, hayvanda bir huzursuzluk oluşturmayacak bir formda olmalı, kolay izlenebilmeli ve veri tabanlarında uzun süreli saklanabilmelidir (Çelikyürek ve Karakuş, 2017).

2.3.1. Biyometrik Kimliklendirmede Kullanılan Yöntemler

Biyometrik kimliklendirme, insan ve hayvanlarda birçok biyolojik verinin değerlendirilmesi ve kaydedilmesi için kullanılmaktadır. İnsan ve hayvanların tanınması, kanıt oluşturulması, hırsızlık, kayıp gibi durumların önlenmesi için kullanılmaktadır (Kumar ve Singh, 2014).

Hayvanlarda en çok kullanılan biyometrik yöntemleri; görsel desenler, burun baskıları, iris desenleri, retina desenleri, yüz tanıma, kulak damar desenleri, ısırık izleri, DNA analizi, davranış ve hareketler olarak gruplandırılabilir (Çelikyürek ve Karakuş, 2017).

2.3.1.1. Görsel Desenler

Bazı türlerin bu yöntemle tanınması kolaydır. Her hayvan için benzersiz olan fenotipik özelliklere bakılır (Çelikyürek ve Karakuş, 2017). Yılanlardaki renkli halkalar, zebraların çizgileri, kazlardaki karın bölgesinde bulunan desenler, kelebek kanatlarında bulunan desenler örnek olarak gösterilebilir. Biyometrik işaretlerden en belirgin olanları, genelde gövde kısımlarında bulunan tüy, kürk veya pulların renklenmesidir. Örnek olarak kaplanlar ve zebralar çizgileri ile tespit edilebilirler; çitalarda ve afrika penguenlerinde benzersiz lekeler vardır; yunusların yüzgeçlerinde bulunan farklılıklar da benzer bir örnektir. Bu yöntemin uygulanması son derece kolay masrafsızdır. Ayrıca hayvanlardaki stresi azaltmak ve doğal davranışlarını korumak amacıyla gözlemler uzaktan yapılabilir (Bugge vd., 2011).

2.3.1.2. Burun Baskıları

Burun baskısı yöntemi daha çok sığırlarda kullanılmaktadır (Çelikyürek ve Karakuş, 2017). Dolandırıcılık ve sahteciliği önlemek için geliştirilmiş olup yöntem basit ve ucuzdur (Stahl vd., 2008; Bugge vd., 2011; Awad vd., 2013).

Burun baskıları, insanlardaki parmak izinin karşılığıdır (Yalçın ve Baykan, 2013). Yapılan çalışmalar burun izlerinin oldukça uzun bir süre hiç değişmediği ve biyometrik kimliklendirmede stabil bir yapı olarak kullanılabileceğini göstermiştir (Çelikyürek ve Karakuş, 2017).

2.3.1.3. İris Desenleri

Biyometrik kimliklendirme yöntemlerinden biri de iris desenlerinin kullanılmasıdır ve gerek insan gerekse hayvanların kimliklendirilmesinde iris taramasından elde edilen desenler kullanılmaktadır (Çelikyürek ve Karakuş, 2017).

İris deseni kullanımı her ne kadar insanlar için geliştirilmiş olsa da son zamanlarda hayvanlarda da kullanılmaktadır (Aydın, 2007; Çelikyürek ve Karakuş, 2017).

2.3.1.4. Retina Desenleri

Retina deseni modeli hayvanlarda benzersiz ve belirgin biyometrik bir özelliktir. Hayvanın doğumundan itibaren başlayan ve hayvanın tüm yaşamı boyunca hiç değişmeyen retina damarlarının şekillerinden oluşmaktadır. Retina tarayıcısı kullanılarak gözdeki damarlar tespit edilmektedir. Yöntemin maliyeti düşüktür ancak mutlaka deneyimli kişiler tarafından uygulanmalıdır (Çelikyürek ve Karakuş, 2017).

2.3.1.5. Yüz Tanıma

Yüz tanıma yönteminde insan parmak izi kadar kolayca özelliklerinin çıkarılabileceği bir yapısı olmadığından, parmak izi kadar eskiye dayanmamaktadır. Yüz tanıma yönteminde insan yüzü için kullanılan bağımsız bileşenler algoritması kullanılmaktadır (Bugge vd., 2011). Yüz tanıma yönteminin hayvanlarda kullanımı üzerine yapılan çalışmalar sınırlıdır ancak oldukça başarılı çalışmalar vardır (Burghardt ve Campbell, 2007; Kakıcı, 2008).

2.3.1.6. Kulak Damar Deseni

Çelikyürek ve Karakuş (2017)'un bildirdiğine göre, kulak damar desenleri insanlardaki parmak izlerinden ilham alınarak kemirgenlerin kulaklarındaki benzersiz kan damarları biyometrik tanımlama yöntemi olarak kullanılmıştır.

2.3.1.7. ısırık İzleri

Bir hayvana ait ısırık izlerinden faydalanılarak adli tıp vakaları açıklanabilmektedir. Ancak bu yöntem bütün hayvanlar için geçerli değildir ve uygulanması bazı durumlarda zor olabilir (Bugge vd., 2011).

2.3.1.8. DNA Analizi

DNA bir bireyi tanımlamak için en kesin yöntem olabilmektedir. Canlıların her bir hücresi kişisel bir haritaya sahiptir (blueprint) ve bu yapı her vücut hücresinde bulunabilir (Burghardt, 2008). DNA analizi için gerekli numuneler salya, tırnak, kan, kıl gibi herhangi bir kaynaktan toplanabilir. Kan haricindeki numunelerden de örnek elde etmek kolaydır (Bugge vd., 2011).

DNA analizi hayvan tanımlamada yeni bir yöntemdir fakat uzun sürmesi ve maliyetli oluşu bir dezavantaj oluşturmaktadır (Skaggs ve Crawford, 2007; Yalçın ve Baykan, 2013; Lu vd., 2014).

2.3.1.9. Davranış veya Hareket

İmza, klavye tuşlarına basma, yazı yazma hareketleri, konuşma esnasında dudaklardaki hareketler, duruş ve yürüme şekli, ses ve konuşma insanlarda davranışsal biyometrik tanımlama yöntemi olarak değerlendirilmektedir (Kakıcı, 2008; Çelikyürek ve Karakuş, 2017).

Benzer şekilde, suda yaşayan hayvanların hareketleri analiz edilerek biyometrik kimliklendirme mümkün olmaktadır (Bugge vd., 2011).


2.4. Makine Öğrenmesi

Günümüz teknolojilerle, açıkça talimat verilmeden görevleri akıllıca yerine getirebilen, akılcı ve insancıl düşünme becerisine sahip sistemlerin üretilmesi mümkündür. Bu sistemlerin oluşturulması Yapay Zekâ (AI: Artificial Intelligence) çalışma alanına girmektedir. Yapay zekâ, makineler tarafından sergilenen insan zekâsı olarak kabul edilir (Jones vd., 2018). Yapay zekâ, en genel tanımıyla en az insan müdahalesi ile akıllı davranışı örneklemek için bir bilgisayarın kullanımını ifade eden genel bir terimdir. Yapay

zekânın, robotların icadı ile başladığı genel kabul görmektedir. Yapay zekâ ayrıca, akıllı makinelerin bilimi ve mühendisliği olarak da tanımlanmaktadır. Yapay zekâ terimi ve tanımı 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, derin öğrenme, yapay sinir ağları ve otomasyon teknolojilerinin yaygınlaşmasıyla birlikte, bu modern teknolojilerin geleneksel hayvancılıkta uygulanması da son yıllarda gündeme gelmeye başlamıştır. Bu teknolojilerin kullanımı, insan işgücünü büyük ölçüde azaltacak, modern üretimde verimliliği artıracak ve ürün kalitesinin iyileştirmesine de çok fazla katkı sağlayacaktır (Neethirajan ve Kemp., 2021).

Makine Öğrenimi (ML), yapay zekânın bir alt dalıdır ve temel olarak yazılımların deneyimlerden öğrenmesini ve belirli bir görevi kendiliğinden geliştirmesini sağlayan bir çalışma alanını temsil eder. ML, minimum insan müdahalesiyle, yazılımların belirli görevleri açıkça programlanmadan öğrenmelerini sağlamayı hedefler. Bu sayede makinelerin davranışları ve karar verme yetenekleri, daha çok insana benzer hale getirilmeye çalışılır. ML’de, yazılımlar belirli bir görev için deneyimlerini ve öğrendiklerini verilerden elde ederler. Veriler, makine öğreniminin "yakıtı" olarak adlandırılır ve makine öğrenimi modelleri oluşturmak için farklı algoritmalar kullanılır. Hangi algoritmanın kullanılacağı, eldeki verilere ve çözülmesi gereken göreve bağlıdır. ML’ye dayalı teknikler, örüntü tanıma, bilgisayarla görme, finans, eğlence, tıp ve tarım gibi birçok farklı alanda başarıyla uygulanmaktadır (El Naqa ve Murphy, 2015). Geleneksel programlama yöntemlerinde, bir ürün oluşturmak için yazılımın yanı sıra verilerin de iyi bir şekilde yazılması ve test edilmesi gerekmektedir. Ancak günümüzde, makine öğrenmesiyle, öğrenme sürecinin sonucunda elde edilen çıktılar verilerle birlikte sisteme girdi olarak sunulur. Bu şekilde, makinenin belirli bir görevi yerine getirmesi için oluşturduğu yazılım veri tabanlıdır. ML’nin geleneksel programlama yöntemlerine göre mimarisi, Şekil 2.1’de gösterildiği gibi farklıdır.



Şekil 2.1. Geleneksel programlama ve makine öğrenmesi (Hayıt, 2021)

Makine öğrenimi aşağıdaki adımdan oluşmaktadır;

- Verilerin elde edilmesi
- Veri setinin hazırlanması
- Model seçimi
- Eğitim
- Değerlendirme
- Hiper parametre ayarlama
- Tahmin

2.4.1. Makine Öğreniminde Öğrenme/Eğitim Yaklaşımları

Makine öğreniminde, denetimli öğrenme, denetimsiz öğrenme, yarı denetimli öğrenme ve takviyeli öğrenme olmak üzere dört ana yaklaşım bulunmaktadır. Bu dört ana yaklaşım, makine öğrenme modelinin nasıl eğitildiği, ne tür verilere ihtiyaç duyulduğu ve hangi tür görevlerin çözülmeye çalışıldığı gibi faktörlere göre seçilir. Her bir yaklaşımın kendine özgü avantajları ve kullanım alanları vardır ve hangi yaklaşımın kullanılacağı belirli bir problemin gereksinimlerine bağlıdır (Hayıt, 2021).

2.4.2. Denetimli Makine Öğrenme Yaklaşımı

Denetimli makine öğrenme modeli, girdi değişkenleri (x) ve çıktı değişkeni (y) arasındaki ilişkiyi modellemek amacıyla kullanılır. Bu modelde kullanılan algoritma, bu değişkenler arasındaki eşleme veya tahmin işlevini temsil eder ($y=f(x)$). Eğitim süreci boyunca, çıktı değişkeni, her adımda izlenir ve denetlenir. Algoritma, sonuçları optimize etmek için sürekli olarak düzeltilir. Algoritma, veri kümesi üzerinde eğitilir ve kabul edilebilir bir performans seviyesine ulaşana kadar ayarlanır. Denetimli öğrenme yaklaşımı, regresyon ve sınıflandırma görevleri gibi bir dizi uygulama için kullanılmaktadır (Chen vd., 2008; Hayıt, 2021).

2.4.3. Denetimsiz Makine Öğrenme Yaklaşımı

Denetimsiz makine öğrenme yaklaşımı, çıktının önceden bilinmediği ve yalnızca girdi değişkenlerinin mevcut olduğu senaryolarda kullanılan bir öğrenme yöntemidir. Bu yaklaşımda, algoritma kendi kendine öğrenme sürecini gerçekleştirir ve verilerden bilgi çıkarmaya çalışır. Temel amaç, veri setindeki desenleri ve ilişkileri anlamak ve verilerin içindeki yapının keşfedilmesini sağlamaktır. Denetimsiz öğrenme, özellikle kümeleme ve ilişkilendirme görevlerini çözmek için kullanılır (Hayıt, 2021).

Kümeleme, benzer özelliklere sahip girdilerin gruplandırılmasını içerir. Veri setindeki benzer veriler, aynı kümeye atanır. Bu, verilerin daha iyi anlaşılmasını ve grupların oluşturulmasını sağlar. Örneğin, müşteri verilerini inceleyerek benzer alışveriş alışkanlıklarına sahip müşterileri aynı kümeye yerleştirebilirsiniz (Hayıt, 2021; Şahin, 2022).

İlişkilendirme ise veri seti içindeki kuralları ve ilişkileri ortaya çıkarma amacını taşır. Özellikle birçok ürünün satıldığı bir mağaza düşünün; ilişkilendirme analizi, müşterilerin hangi ürünleri birlikte satın aldığını anlamak için kullanılabilir. Bu, öneri sistemleri ve pazarlama stratejileri oluşturmak için önemli bilgiler sağlayabilir. Denetimsiz öğrenme algoritmalarına örnek olarak temel bileşen analizi ve K-Ortalama kümeleme analizi gösterilebilir. Bu yöntemler, veri setlerindeki karmaşıklığı azaltmak ve anlamlı yapıları ortaya çıkarmak için kullanılır (Lantz, 2013; Şahin, 2022).

2.4.4. Yarı Denetimli Makine Öğrenme Yaklaşımı

Yarı denetimli öğrenme yaklaşımı, sınırlı miktarda etiketlenmiş veri ile büyük miktarda etiketlenmemiş verinin bir arada kullanıldığı bir öğrenme yöntemidir. Bu yaklaşım hem denetimli hem de denetimsiz öğrenme yeteneklerini bir araya getirir. Yarı denetimli öğrenme süreci genellikle iki temel adımdan oluşur. İlk adım, denetimsiz bir makine öğrenme algoritması kullanarak benzer verileri kümeleme veya gruplandırma işlemidir. Bu, veri setindeki benzer veri noktalarını tanımlamayı amaçlar. Sonraki adımda, az miktarda etiketlenmiş verinin özellikleri kullanılarak etiketlenmemiş verilere etiket atama işlemi gerçekleştirilir. Bu, az miktarda etiketlenmiş veriyi kullanarak modelin etiketleme yeteneğini geliştirmeyi hedefler. Tüm veriler etiketlendikten sonra, son aşamada belirli bir görevi yerine getirmek için denetimli öğrenme yaklaşımı uygulanabilir. Bu görev, verilerin

etiketlerini kullanarak bir modelin eğitilmesi veya tahminlerin yapılması olabilir. Yarı denetimli öğrenme, etiketleme maliyetini azaltmak ve sınırlı etiketli veriyle daha iyi modeller oluşturmak için yaygın olarak kullanılır (Hayıt, 2021).

2.4.5. Takviyeli (Pekiştirmeli) Makine Öğrenme Yaklaşımı

Takviyeli öğrenme yaklaşımında, makine öğrenme modeli, pekiştirme araçlarına veya geri bildirimlere dayalı kararlar serisi oluşturmak için eğitilir. Makine, karmaşık ve belirsiz durumlarda bir sonuca ulaşmayı öğrenir ve bu süreç boyunca hedefe ulaştıkça pekiştirilir.

Takviyeli öğrenme, denetimli öğrenmeden farklıdır çünkü burada tipik bir çıktı veya hedef yoktur. Takviyeli öğrenme yaklaşımında, pekiştirme aracı, bir görevi gerçekleştirmek için adımları belirleyen karar mekanizmasını temsil eder. Makine, eğitim verileri veya önceden tanımlanmış çıktılar olmadığında, kendi öğrendiği deneyimlere dayanarak kararlar alır.

Takviyeli öğrenme, özellikle karmaşık ve gerçek dünya uygulamalarında kullanışlıdır, çünkü burada çok sayıda olası durum ve hareket vardır ve makine kendi kendine öğrenerek bu karmaşıklıklarla başa çıkmayı öğrenir (Şahin, 2022).

2.5. Geleneksel Makine Öğrenim Sınıflandırıcıları

Görüntü sınıflandırma basit bir ifadeyle, bir görüntünün hangi sınıfa ait olduğuyla ilgilenmektedir. Makine öğreniminde birçok farklı sınıflandırma görev türü ile her bir görev için kullanılabilecek modellemeye yönelik özel yaklaşımlar bulunmaktadır (Chou vd., 2018).

2.5.1. Destek Vektör Makineleri

Destek Vektör Makineleri (SVM: Support Vector Machines) veya destek vektör ağları, büyük veri sınıflandırma problemlerini çözmeye yardımcı olan klasik bir öğrenme tekniğidir. SVM, Vapnik ve meslektaşları tarafından geliştirilmiştir (Vapnik vd., 1997; Suthaharan, 2016). SVM, özellikle büyük veriler için yardımcı olmaktadır (Chou vd., 2018).

2.5.2. Karar Ağaçları

Karar ağaçları, veri madenciliği için önemli bir metodolojidir. Her düğüm, veri örneklerinin bir alt kümesini içerir ve her yaprak düğüm bir karara karşılık gelir. Kök düğüm tüm veri setini kapsar ve ağaç, özellik alanını bölme stratejisini temsil eder (Selvi, 2019).

2.5.3. Rastgele Orman

Rastgele Orman (RF), rastgele seçilen karar ağaçlarını kullanarak sınıflandırma yapar. Bu, aşırı uyumu önler ve varyansı azaltır. RF, bağımsız olarak eğitilen ağaçları bir araya getirir ve sonuçların ortalamasını alır. Her özellik için rastgele alt kümeler oluşturur ve bunlarla küçük ağaçlar oluşturarak en iyi özellikleri belirlemeyi hedefler (Şahin, 2022; URF, 2023).

2.5.4. K-En Yakın Komşu

K-En Yakın Komşu (KNN: K-Nearest Neighbors) algoritması hem regresyon hem de sınıflandırma problemlerinde kullanılabilir. KNN, tahmin gücü, hesaplama süresi ve hedef çıktıyı yorumlama kolaylığı gibi avantajlara sahiptir. Ayrıca, karmaşık sınıflandırıcılarla karşılaştırmak için kullanılabilir (Mukid vd., 2018).

2.5.5. Yapay Sinir Ağları (Artificial Neural Network)

Yapay sinir ağları (YSA), yapay zekânın araştırma alanı içinde makine öğreniminin bir alt alanıdır (Walczak, 2019). YSA, bilginin iletilmesi, işlenmesi ve depolanması olmak üzere üç temel bileşenden oluşur (Hornik, 1991). YSA, örneklerden öğrenebilen gelişmiş bilgisayarlı öğrenme algoritmalarıdır (Van Gerven ve Bohte, 2017).


Yapay sinir ağları, birçok karmaşık gerçek dünya problemini çözmede kapsamlı olarak alanı bulan ve nispeten yeni bir hesaplama/bilgi işleme aracıdır. YSA'nın çekiciliği, esas olarak doğrusal olmama, yüksek paralellik, hata ve gürültü toleransı ile öğrenme ve genelleme yetenekleri ile ilgili dikkat çekici bilgi işleme özelliklerinden kaynaklanmaktadır (Basheer ve Hajmeer, 2000).

YSA, makine öğrenimi için kullanılan ve insanların yaptığı gibi birçok nitel ve nicel sorunun doğasını yorumlayabilen bir grup algoritmadır. Zengin ve kapsamlı verilere

maruz kalarak gerçek dünya örneklerinden ve deneyimlerinden öğrenebilirler ve veri kümelerinde var olan içsel kalıpları ve korelasyonları sınıflandırmalarını ve tahmin etmelerini sağlarlar. İnsan beynindeki biyolojik sinir ağlarının yapısından esinlenilmiştir (Hertz, 2018).

2.6. Derin Öğrenme

Derin Öğrenme (DL: Deep Learning), yapay zekâ içinde bir alan olan makine öğreniminin bir alt dalıdır (Sahiner vd., 2019). Derin öğrenm, makine öğrenmesi ve yapay zekâ arasındaki ilişki Şekil 2.2’de gösterilmiştir.



Şekil 2.2. Derin öğrenmenin yapay sinir ağı ve makine öğrenmesindeki konumu (Sahiner vd., 2019)

Derin öğrenme, ham verilerden başlayarak, her sınıfa ait temsil verilerini daha yüksek soyut düzeyde temsile dönüştüren doğrusal olmayan öğrenme yöntemlerini içeren bir alandır (LeCun vd., 2015). Bu özel metot, makinelerle verileri farklı kategorilere ayırmayı öğretmek insan zekâsını taklit etmeyi amaçlar. Derin öğrenme sayesinde makineler, görüntüler, videolar, metinler veya ses dosyaları gibi verileri kullanarak herhangi bir görevi insan benzeri bir şekilde tanımlayabilir ve gerçekleştirebilir. Sürücüsüz araçlar, kişiselleştirilmiş öneri sistemleri ve sesli asistanlar gibi teknolojiler, günlük yaşamımızdaki derin öğrenmenin pratik örnekleridir. Doğru verilerle eğitilen

bilgisayarlar, derin öğrenmeye dayalı olarak insan benzeri başarıları tekrarlayabilir. Derin öğrenme, bilgisayarların büyük veri kümelerine maruz bırakılmasına dayalı tekrarlı öğrenme yöntemlerine odaklanır. Bu yaklaşım, bilgisayarların desenleri öğrenmesine ve değişen koşullara uyum sağlamasına yardımcı olur. Verilere sürekli maruz bırakılarak, farklılıkların ve mantıkların anlaşılmasını teşvik eder ve güvenilir sonuçlar elde edilmesini sağlar. Derin öğrenme, son yıllarda farklı ve karmaşık problemlerde daha güvenilir hale getirilmiştir (Hayıt, 2021).

2.6.1. Evrişimsel Sinir Ağları (CNN)

Evrişimsel Sinir Ağları (CNN: Convolutional Neural Networks), özellikle görüntü tanıma için yaygın olarak kullanılan bir Derin Öğrenme (DL) algoritmasıdır (Nisha ve Meeral, 2021). CNN, insan beyninin korteks bölgesinin çalışmasından ilham alarak oluşturulmuş ve bilgisayarla görme alanında birçok probleme başarıyla uygulanmıştır (Krizhevsky vd., 2017). Temelde yapay sinir ağlarına benzeyen bir yapıya sahip olan CNN, ağ yapısında evrişim adı verilen matrisleri kullanır. Verileri işlerken "tensör" adı verilen üç boyutlu yapıları kullanır, bu yapılar birden fazla iki boyutlu matris kanalından oluşur. CNN, bu tensör verilerini işlemek ve karmaşık işlemler gerçekleştirmek için evrişim filtreleri kullanabilen bir mimari sunar (Litjens vd., 2017).

Genellikle, tipik bir CNN mimarisi, ardışık olarak evrişimli filtreler ve havuzlama katmanları uygulayan ileri beslemeli katmanlardan oluşur. CNN'nin son aşamasında ise, önceki katmanlardan gelen harita özelliklerini sınıflandırmada kullanmak için vektörel bir yapıya dönüştüren tam bağlantılı katmanlar bulunur. Bu sayede CNN, görüntü işleme ve sınıflandırma görevlerinde büyük başarı elde edebilir (Hayıt, 2021).


2.6.2. YOLO Gerçek Zamanlı Nesne Algılama Yaklaşımı

YOLO (You Only Look Once), ilk olarak 2015 yılında ortaya çıkan bir nesne tespit algoritmasıdır. Zaman içinde farklı versiyonları geliştirilmiştir. YOLO terimi, "Sadece Bir Kez Bak" anlamına gelir. YOLO'nun tercih edilme sebeplerinden biri hızı ve doğruluğudur. Daha önce RCNN, Fast RCNN ve Faster RCNN gibi algoritmalar sıkça kullanılırken, YOLO'nun hız ve doğruluk açısından daha etkili olması tercih edilmesine neden olmuştur. YOLO, giriş görüntüsünü algoritmadan sadece bir kez geçirdiği için diğer

nesne tespit algoritmalarına göre daha hızlıdır. Ayrıca YOLO, nesne tanıma işlemlerini gerçek zamanlı, yüksek doğrulukla ve hızla gerçekleştiren modeller sunar.

YOLO, bir görüntüyü tek bir evrimsel sinir ağı modeline geçirir ve görüntüyü ızgaralara böler. Her ızgara hücresi, sınırlayıcı kutuları (bounding boxes) ve ilgili güven puanlarını tahmin eder. Bu güven puanlarına dayalı olarak sınırlayıcı kutu içindeki nesnenin sınıfı belirlenir (Shinde vd., 2018).

YOLO'nun genel yapısı, Şekil 2.3'de görülen YOLOv5 ağ mimarisi ile açıklanabilir. Bu yapısı üç ana bölümden oluşur: omurga (backbone), boyun (neck) ve baş (head). Omurga kısmı, giriş görüntülerinden öznitelik bilgilerini çıkarır. Boyun kısmı, çıkarılan öznitelik bilgilerini birleştirir ve öznitelik haritaları oluşturur. Baş bölümü ise öznitelik haritalarını kullanarak nesneleri algılar (Mastromichalakis, 2020).



Şekil 2.3. YOLOv5 mimarisinin genel yapısı (Xu vd., 2021; Gündüz, 2023)


YOLO algoritmasının çeşitli sürümleri bulunmaktadır, ancak en güncel ve hızlı versiyonu YOLOv5'tir (Jocher vd., 2020). Zaman içinde geliştirilen YOLO v2, v3 ve v4 algoritmalarından sonra Jocher vd. (2020) tarafından mimarinin yeni sürümü olan YOLOv5 geliştirildi. YOLOv5, önceki sürümlerden farklı bir PyTorch uygulamasına dayanmaktadır (Paszke vd., 2019) ve işlem süresini önemli ölçüde azaltmıştır (Tablo 2.5). Bu ağ modeli, nesne algılama doğruluğu ve hızı açısından önceki sürümlere göre oldukça yüksektir. Ayrıca, YOLOv5'in ağ modelinin ağırlık dosyalarının boyutu, önceki sürüm YOLO v4'e göre yaklaşık %90 daha küçüktür (Jocher vd., 2020; Gündüz, 2023).

Tablo 2.5. YOLO (v3, v4, v5s ve Tiny) modellerinin özellikleri (Jocher vd., 2020; Gündüz, 2023)

YOLO v3	YOLO v3-Tiny	YOLO v4	YOLO v4-Tiny	YOLOv5s
---------	--------------	---------	--------------	---------

Katman Sayısı	107	24	162	38	224
Ağırlık (MB)	236	33.7	245	23.0ca	28.8Ağu
AP@0.50	58.2	35.4	48.7	40.2	56.8
Omurga	DarkNet53	DarkNet53	CSPDarkNet53	CSPDarkNet53	CSPDarkNet53
Boyun	FPN	FPN	SPP and PANet	SPP and PANet	PANet
Baş	$B \times (5 + C)$	$B \times (5 + C)$	$B \times (5 + C)$	$B \times (5 + C)$	$B \times (5 + C)$
Sinir Ağı Türü	FCNN	FCNN	FCNN	FCNN	FCNN

YOLO, tek aşamalı bir evrişimsel sinir ağı (Convolutional Neural Network, CNN) tabanlı bir modeldir ve nesne algılamak için özel bir ön işleme ihtiyaç duymaz (Şekil 2.4). Tek aşamalı dedektörlere örnek olarak SSD (Single Shot Detector) ve YOLO modelleri verilebilir (Liu vd., 2016). SSD algoritması, farklı katmanlardaki özellik haritalarını kullanarak küçük nesneleri tespit etmek için tasarlanmıştır. Öte yandan, YOLO, bir resmi tek bir evrişimsel sinir ağı modeline geçirir ve resmi ızgaralara böler. Bu işlem sırasında ızgara hücrelerinde sınırlayıcı kutular ve ilgili güven puanlarının tahminini yapar. Tahmin edilen güven puanlarına göre, sınırlayıcı kutular içinde bulunan nesnenin sınıfı belirlenir (Shinde vd., 2018).




Şekil 2.4.YOLO modeli çalışma prensibi (Redmon vd., 2016; Biçgi, 2022)

YOLOv5, nesne algılama amacıyla tasarlanmış bir modeldir ve giriş görüntülerinden özellikler çıkarma sürecini içerir. Bu özellikler daha sonra nesnelerin etrafına sınırlayıcı kutular çizmek ve sınıflarını tahmin etmek için bir tahmin sistemi tarafından kullanılır. YOLOv5'in ana hedefi, çıkarım süresine (X eksen) göre oldukça yüksek performanslı bir nesne tespit modeli üretmektir (Y eksen). YOLOv5'in, bu amacı yerine getirme konusunda diğer son teknoloji yöntemlere kıyasla son derece iyi performans gösterdiği


gözlemlenmektedir.

YOLOv5, dört ana versiyona sahiptir: küçük (s), orta (m), büyük (l) ve ekstra büyük (x), her biri giderek daha yüksek doğruluk oranları sunar. Her varyantın eğitim süresi de farklılık gösterir. En isabetli YOLOv5 modeli olan YOLOv5x, görüntüleri EfficientDet modeline göre benzer doğruluk seviyesiyle daha hızlı işleyebilir (Chen vd., 2023). Şekil 2.5’de YOLOv5’in tüm varyantlarının EfficientDet’ten daha hızlı bir eğitim yapabildiği görülmektedir.



Şekil 2.5. YOLOv5 varyantları çalışma hızları (Chen, vd. 2023).

Çalışmada farklı manta yüz resimlerinin doğru sınıflandırılmasını sağlayan bir yapı önerilmiştir. Çeçen (2023)’in YOLOv5 algoritması kullanarak ratlarda uterus dokusu östrus dönemlerini belirlediği çalışmaya benzer yöntem kullanılmış olup Şekil 2.6’da gösterildiği gibi üç aşamadan oluşmaktadır. Bunlar; veri ön işleme, özelliklerin çıkarımı için YOLOv5 mimarisi ile sınıflandırma ve performans değerlendirme metrikleri aşamasıdır.




Şekil 2.6. Önerilen yöntem aşamaları (Çeçen, 2023)

2.7. Makine Öğrenimine Dayalı Hayvanları Tanıma Çalışmaları

Çalışmada kullanılan yöntemler çerçevesinde ilgili metotlara ilişkin literatür çalışmaları bu bölümde sunulmuştur. Tez çalışması kapsamında hayvanlarda yüz tanıma özelliklerinin geliştirilmesi başta olmak üzere benzer alanda yapılmış çalışmalar incelenmiştir.

Hayvan tanıma ve sınıflandırma bilgisayarla görmenin en önemli konusu olarak kabul edilir. Hayvanları resim ve video verilerine göre sınıflandıran pratik bir hayvan yüzü sınıflandırma sistemi, makine öğreniminde çok önemli bir konu olarak kabul edilmektedir. Ancak, otomatik bir tanıma sisteminde şöyle bir sorun vardır ki, hayvanlar bir görüntüde bireysel olarak görünmezler çünkü çevrelerindeki tüm doğal nesneler de görüntüde yer alırlar. Dolayısıyla, bilgisayarın görüntüyü, insanların sadece hayvana konsantre olabileceği şekilde düzeltmesi gerekmektedir. Ayrıca hayvanlar farklı aydınlatma koşulları, bakış açıları, ölçekler ve şekiller altında görünebilir. İnsan yüzlerini sınıflandırmak için geliştirilen yöntemler büyük bir doğrulukla denenmiştir, ancak hayvanların karmaşık sınıf içi değişkenlikleri ve sınıflar arası benzerliğe sahip hayvan sınıflarının çeşitliliği nedeniyle hayvan sınıflandırmaları için bu yöntemler doğruluktan uzaktır. Araştırmacılar, bu sorunları çözmek için her birinin yararları ve sakıncaları olan çeşitli yaklaşımlar denemişlerdir. Bununla beraber son yıllarda Evrişimsel Sinir Ağları (CNN) tabanlı sınıflandırma yöntemleri oldukça ilgi görmektedir. CNN katmanları derin anlam ifade ettiğinde, çok sayıda katmana sahipse buna Derin Konvolüsyonel Sinir Ağları (Deep Convolutional Neural Networks-DCNN) denmektedir. Bu network'lere örnek olarak AlexNet, GoogleNet, VGG19, vb. gösterilebilir. Bununla birlikte, bu ağlar, herhangi bir özel türden bağımsız olarak tamamen sınıflandırma görevine odaklanmıştır. CNN, robotlarda ve kendi kendine giden arabalarda görüşü güçlendirmenin yanı sıra hayvanları, yüzleri, nesneleri ve trafik işaretlerini tanımlamada başarılı olmuştur (Khan vd., 2020).

Yukarıdaki bilgiler ışığında Khan vd. (2020), yüksek doğruluk oranı veren kendi sınıflandırma modellerini oluşturmak için bir çalışma yapmışlardır. Çalışmasında yeni bir yöntem deneyerek, görüntü özelliklerini büyük ölçekte çıkaran ve analiz eden tam bağlantılı Çift Derin Evrişimli Sinir Ağı (DCNN) denemişlerdir. Çalışmada veriseti olarak on hayvan sınıfına ait on bin görüntü ve DCNN kullanılmıştır (Şekil 2.7). Daha iyi öğrenme süreci için eğitim görüntülerinin şekillerini değiştirmek üzere görüntü artırımı da kullanılmıştır. Çalışma sonuçları %92,0 oranında bir başarı sağlayarak, benzerlerini geride bırakmış ve daha az bilgi işlem maliyeti sağlamıştır.




Şekil 2.7. Sınıflandırılan hayvanlar (Khan vd., 2020)

Bilgisayar görüşü, bilgisayar biliminin önemli çalışma alanlarından biridir. Bir bilgisayarın, bir görüntünün içeriğini anlamasını sağlamak, insan görmesine benzer. Bunun kilit noktası, bir bilgisayarın, insanların nesneleri algılama biçimini taklit ederek bir görüntüdeki nesnelerin kalıplarını öğrenmesini sağlamaktır. (Li vd., 2020). Dikkate değer yaklaşım, Hubel ve Wiesel, (1968) tarafından modellenen bir hayvan beynindeki görsel sinir sistemine benzer bir yapıya sahip olduğunu belirttiği Neocognitron'dur. Bu yaklaşım, bilgisayar görüşü için daha birçok Evrimsel Sinir Ağı (CNN) mimarisine ilham vermiştir (Fukushima, 1980; Li vd., 2020).

Evrimsel Sinir Ağlarını kullanarak hayvanları tespit etmeye yönelik yapılan çalışmalarda asıl görüntü önünde bulunan engelleyicilerin genellikle bir algılama modelinin saptana bilirliliğini etkilediğinden, birçoğu kafes parmaklıklarının arkasındaki hayvanları tespit edememiştir. Bunun temel sebebi, hayvanları tespit etmek için eğitilmiş mevcut modellerin çoğunun, bir eğitim setinde olduğu gibi kafes parmaklıklarının arkasında yeterli sayıda hayvan resminin olmamasıdır. Ayrıca, kafes olmadan alınan eğitim amaçlı hayvan görüntülerinin de modelin algılama performansını artırmıştır (Li vd., 2020).

Birçok CNN mimarisi, pek çok araştırma problemini çözmek için üstün başarı sağlamıştır. Bununla birlikte, nesne algılama performansı giderek artmakta ve bu nedenle, genellikle canlılar (örn. bitkiler, hayvanlar ve insanlar) olmak üzere birçok uygulamada kullanılmaktadır. Normalde, model belirli bir görevi yerine getirmek için tasarlandığında

önemli bir sorun yoktur. Hatta çoğu durumda, verilen bir görevde insanlardan bile daha iyi performans gösterebilirler. Bununla birlikte, bir görüntüde veya videoda bir nesneyi engelleyen bir kafes veya örgü deseni olduğunda, model bu tür bir durumu tespit etmede başarısız olma eğilimindedir. Li vd. (2020) tarafından yapılan çalışmada örnek olarak panda ve geyikleri kullanmışlardır. Eğitim verilerini bu çalışma için özel olarak toplamışlardır. Transfer öğrenme yaklaşımı ve önceden eğitilmiş ağırlıkları ile birlikte ana ağ olarak M2Det kullanılmıştır (Şekil 2.8). Çalışmada, eğitim amacıyla alınan kafes arkasındaki hayvan görüntülerinin, hayvanların tespit edilmesinde büyük ölçüde etkili olduğu bulunmuştur.



Şekil 2.8. Kafes arkasında algılanan pandalar (Li vd., 2020)

Kumar vd. (2018) yaptıkları çalışmada sığırların burun deseni görüntülerini kullanarak makine öğrenme teknikleriyle sığırları %99,89 doğrulukta tanımlamayı başarmışlardır (Şekil 2.9).




Şekil 2.9. Veritabanındaki burun görüntülerinden bazıları (Kumar vd., 2018)

Dandıl vd. (2019) yaptıkları çalışmada, sığırların yüzlerinden tanınması için Daha Hızlı Bölgesel-Evrişimsel Sinir Ağları (Faster R-CNN) kullanmışlardır. Sığır yüz görüntüleri ön-eğitilmiş bir ağ üzerinde eğitildikten sonra, gerçekleştirilen test işlemlerinde sığır yüz görüntüleri %98,44 doğruluk ile başarılı bir şekilde sınıflandırılmıştır. Önerilen bilgisayar destekli bu yaklaşımın, sığırların yüzlerinin tanınmasında ikincil bir araç olarak kullanılabileceği tavsiye etmişlerdir (Şekil 2.10).



Şekil 2.10. Başarılı şekilde tanınan farklı sınıflara ait sığır yüzleri (Dandıl vd., 2019)

McLennan ve Mahmoud (2019) yaptıkları çalışmalarında, koyunlarda acı ve ağrının, derin öğrenme yardımıyla yüzlerinden okunabilmesi için çalışma yapmışlar ve araştırmacılar koyun yüzlerini bölgelere ayırarak acı ve stresi belirlediklerini bildirmişlerdir (Şekil 2.11).



Şekil 2.11. Koyun acı çekme algılaması (McLeenan vd., 2019)

Xu vd. (2020) quadcopter kullanarak yaptıkları çalışmada, geniş meralar ve besi yerleri gibi ortamlarda sığır sayımı bağlamında en yeni örnek segmentasyon çerçevesi olan Mask R-CNN'nin uygulamasını göstermişlerdir. Araştırmadaki deneysel sonuçlar, sanal çerçeve ve çevrimdışı quadcopter görüş sistemleri meralarındaki sığırları saymada %94 ve besi alanlarında %92 doğrulukla çevrimdışı güvenilir bir şekilde performans gösterme potansiyelini göstermiştir (Şekil 2.12).



Şekil 2.12. Sığır algılama ve sayım algoritması (Xu vd., 2020)

Fuentes vd. (2020) tarafından yapılan araştırmada, RGBD (renkli ve derinlik imgelerini birlikte sunan) kameralar kullanılarak bir ineğin kalp atış hızı, solunum hızı ve ani hareketleri tahmin etmek için uygulanan invazif olmayan bilgisayarlı görme yöntemleri ile göz sıcaklığı, süt üretimi ve kalitesini tahmin etmek için makine öğrenimi modellemesi denenmiştir. 102 farklı inekten yalnızca kameralardan gelen girdileri kullanan bir yapay sinir ağı modelinin kullanarak günlük süt verimliliği, süt yağı ve süt proteini tahmin etmede yüksek doğruluk ($R=0.96$) göstermiştir. Araştırmacılar, 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 geleneksel süt çiftliklerinde kolaylıkla kullanılabilir olduğunu bildirmişlerdir (Fuentes vd., 2020).

Dutta (2021) yaptığı çalışmada, koyunları ırklarına göre sınıflandırmayı amaçlamıştır. Temel olarak 4 ırk ele alınmış ve sinir ağıları uygulanarak koyun ırkları sınıflandırılmıştır. Görev boyunca, CNN modeli eğilirken %99,97, model test edilirken %87,1 doğruluk elde edilmiştir.

3. MATERYAL VE YÖNTEM

3.1. Materyal

Bu çalışmada, Yozgat ili Merkez ilçede yer alan 60 başlık manda işletmesinde kayıtları bulunan 8 adet mandanın görüntüleri alınmıştır. Çalışma süresince farklı zaman dilimlerinde, kamera yardımı ile çiftlikte bulunan mandaların yüz resimleri ile görüntü kayıt işlemleri yapılarak veri seti oluşturulmuştur. Görüntü alınan mandaların sağlıklı ve farklı yaşlarda olmasına dikkat edilmiştir. Görüntüler uygun bir mesafeden farklı açılardan mandanın yüzü görünecek şekilde kaydedilmiştir (Şekil 3.1). Çalışma boyunca görselleri elde edilen mandalar 0-7 aralığında numaralandırılmıştır.

Ham veri seti toplamda 2324 adet görselden oluşacak şekilde elde edilmiştir. Ham veri setine ilişkin istatistikler Tablo 3.1’de sunulmuştur.

Tablo 3.1. Ham veri setine ilişkin istatistikler

0	1	2	3	4	5	6	7	Toplam
422	384	192	301	277	286	193	269	2324




Şekil 3.1. Mandaların görüntüsünü alma çalışması

3.2. Yöntem

3.2.1. Veri Artırma

Günümüzde derin öğrenme, Makine Öğrenmesi (ML) ve Derin Sinir Ağları (DNN) içerisinde en hızlı büyüyen alandır. Pek çok DNN yapısı arasında, Evrimsel Sinir Ağları (CNN) görüntü analizi ve sınıflandırma amacıyla kullanılan ana ekipmandır. Büyük başarıları ve perspektifleri olmasına rağmen, derin sinir ağları ve beraberindeki öğrenme algoritmalarının üstesinden gelinmesi gereken bazı zorlukları vardır. Bu zorlukların üstesinden gelinmesinin yollarından biri de, Veri Artırımı (Data Augmentation)'dır (Mikołajczyk ve Grochowski, 2018). Veri artırımı terimi, gözlemlenmemiş verilerin veya gizli değişkenlerin tanıtılması yoluyla yinelemeli optimizasyon veya örnekleme algoritmaları oluşturma yöntemlerini ifade eder (Van Dyk ve Meng, 2001). Veri artırımı genellikle görüntüyü yatay çevirme, renk alanı büyütme ve rastgele kırpmaya gibi basit dönüşümlerden gelir. Artırılmış veriler, olası veri noktalarının daha kapsamlı bir kümesini temsil edecek, böylece eğitim ve doğrulama kümesi ile gelecekteki test kümeleri arasındaki mesafeyi en aza indirecektir (Shorten ve Khohsgoftaar, 2019).

Hem geleneksel hem derin öğrenme modelleri için veri artırımında geleneksel veri artırım yöntemleri kullanılmıştır. Her bir görüntü, rastgele döndürme, rastgele parlaklık/kontrast ayarı ve yatay/dikey çevirme gibi yaygın veri artırma teknikleri kullanılarak artırılmıştır. Örnek bir manda yüz görüntüsünün artırılmış form örnekleri Şekil 3.2 üzerinde sunulmuştur.



Şekil 3.2. Artırılmış görüntüler

A orijinal görüntü, B parlaklığı değiştirilmiş, C kontrastı değiştirilmiş, D dikey olarak çevrilmiş, E yatay olarak çevrilmiş, F rastgele döndürülmüş

Çalışmanın önerilen derin öğrenme modeli olan YOLOv5 modelinin eğitiminde kullanılmak üzere; Roboflow etiketleme aracı kullanılarak resimler etiketlenmiş ve resimler artırılmıştır. Toplamda 9595 adet resim elde edilmiştir. Bu resimlerin 8400 tanesi eğitim için, 806 tanesi doğrulama seti olarak ve 389 tanesi test için kullanılmıştır. Veri Setine aşağıdaki linkten ulaşılabilir:

https://app.roboflow.com/waterbuffalo/buffalo_22/browse?queryText=&pageSize=50&startingIndex=0&browseQuery=true

Geleneksel yaklaşımların analiz çalışmalarında ise her sınıf için 500 adet resim oluşturularak veri artırımı sağlanmış ve toplamda 4000 adet veri oluşturulmuştur. Aynı veri seti InceptionV3 modelinin eğitimi, doğrulanması ve test edilmesi için de kullanılmıştır. Veri artırımı sonucu geleneksel yaklaşımlar ve InceptionV3 için kullanılan veriseti istatistikleri Tablo 3.2’de sunulmuştur.

Tablo 3.2. Veri artırımı sonrası veri istatistikleri

0	1	2	3	4	5	6	7	Toplam
500	500	500	500	500	500	500	500	4000

3.3. Geleneksel Görüntü Sınıflama Analizi

3.3.1. İstatistiksel Öznitelik Çıkarımı

Geleneksel anlamda doku, insanın görsel algısının önemli bir unsurudur. Sayısal doku ise sayısal görüntü verileri kullanılarak birçok bilgisayarla görme ya da bilgisayarlı görü uygulamalarında kullanılmaktadır. Normalde bir insan gözüyle farklı dokuları ayırt etmek başka bir deyişle farklı dokuları sınıflandırmak ya da bir görüntü üzerindeki kusuru fark etmek kolay olabilir ancak yapay zekâ tarafında bu uygulama daha farklı ele alınmaktadır.

Basitçe doku analizi, özellikle bilgisayarla görme alanında görüntü elde etme, görüntü işleme, görüntü çoğaltma vb. birçok uygulamayı içerisinde barındıran geniş bir yapay zekâ alanıdır. Nesne algılamadan, endüstriyel otomasyon, belge görüntü analizi, tıbbi uygulamalar (Hayit ve Çınarer, 2022) ve ziraat sektörüne (Hayit vd., 2021; Hayit vd., 2023) kadar birçok alanda kullanılmaktadır. Bu alanlar görüntü işleme, sınıflandırma, bölütleme (segmentasyon) veya sentezleme gibi uygulamalar için sayısal doku parametrelerini kullanır. Makine öğreniminde görüntü sınıflama için geleneksel olarak dokuyu temsil eden özniteliklerin çıkarılması gerekir. Humeau-Heurtier (2019), makalesinde görüntüdeki dokuyu temsil eden bu öznitelikleri çıkarım metotlarını gruplamıştır. Bu gruplardan biri olan istatistiksel yaklaşım, nesne algılama ve görüntü sınıflandırma dahil olmak üzere çeşitli bilgisayarlı görü uygulamalarında yarım yüzyılı aşkındır kullanılmaktadır (Haralick vd., 1973). Temelde istatistiksel yaklaşımlar, görüntüdeki gri seviyelerin uzamsal dağılımlarının bir takım istatistiksel hesaplamalara dayalı olarak özniteliklerinin çıkarılmasına odaklanır. Çıkarılan öznitelikler geleneksel ya da modern bir sınıflandırıcı kullanılarak sınıflandırılır.

Bu çalışmada popüler istatistiksel doku öznitelik çıkarım metotlarından Gri seviye eş-oluşum matrisi (GLCM: Gray Level Co-occurrence Matrix) ve Yerel İkili Örüntüler (LBP: Local Binary Patterns) metotları kullanılmıştır. Geleneksel uygulamalara ek olarak renkli görüntülerin sadece gri pikselleri kullanılmamış; aynı zamanda renkli pikselleri de farklı renk uzayları işe koşularak değerlendirilmiştir.

3.3.1.1. Gri Seviye Eş-Oluşum Matrisi (GLCM) Öznitelik Çıkarımı

Haralick 1979 yılında GLCM yöntemini önermiştir. GLCM, istatistiksel doku analizi için güçlü bir yöntemdir (Manjunath ve Ma, 1996; Soh ve Tsatsoulis, 1999; Nikoo ve Mahmoud, 2011) ve ikinci dereceden özelliklerin istatistiksel ölçümleri kullanılarak

görüntü sınıflandırması için kullanılmıştır (Pantic vd., 2016). GLCM öznitelikleri, bir görüntüde belirli bir mesafe ile ayrılmış iki piksel arasındaki özel ilişki kullanılarak hesaplanır (Yogeshwari ve Thailambal, 2021). Gri Seviye Eş-Oluşum Matrisi yönteminin etkili bir doku tanımlayıcı olduğu belirtilmiş ve diğer doku analiz yöntemlerine göre daha iyi doğruluk değerine ve hesaplama süresine sahip olduğu belirtilmiştir (De Siqueira vd., 2013; Zhu vd., 2015). Ayrıca GLCM'nin farklı renk uzaylarına uygulanabilecek şekilde geliştirilebileceği de belirtilmiştir (Tou vd., 2009; Selvarajah ve Kodituwakku, 2011; Metre ve Ghorpade, 2013). Yapılan çalışmalar incelendiğinde yüz tanımda GLCM'nin tek başına kullanıldığı ya da dahil olduğu modellerin geliştirildiği görülmüştür (Kumar vd., 2020; Thepade ve Dhake, 2021; Veerashetty vd., 2022).

Bu çalışmada GLCM öznitelik çıkarım metotlarından Energy (Haralick vd., 1973), Contrast (Haralick vd., 1973), Entropy (Haralick vd., 1973), Homogeneity (Haralick vd., 1973), Correlation (Haralick vd., 1973), Variance (Haralick vd., 1973, Assefa vd., 2010), SumAverage (Haralick vd., 1973, Assefa vd., 2010), Dissimilarity (Thibault, 2009) ve AutoCorrelation (Aerts vd., 2014) olmak üzere dokuz öznitelik kullanılmıştır.

3.3.1.2. Yerel İkili Örüntüler (LBP) Öznitelik Çıkarımı

Ojala vd. (1996) tarafından LBP yöntemini önermiştir LBP, düşük hesaplama karmaşıklığı ve maliyeti ile popüler bir öznitelik çıkarıcı olma konumunu korumaktadır (Nanni vd., 2017). LBP, yerel yapıların analizini diğer istatistiksel yöntemlerde olduğu gibi ilişkilendirir. LBP'de her pikseli merkeze alan bir I_c değeri etrafındaki dairesel (yarıçapı R olan) komşuluğun değeri dikkate alınarak şu formülle hesaplanır:

$$LBP(N, R) = \sum_{n=0}^{N-1} s(I_n - I_c) 2^n$$

Bu formülde N komşuluk piksel sayısını, R yarıçapı temsil eder ve $s(x)$ için; $x \geq 0$ ise $s(x) = 1$; aksi takdirde $s(x) = 0$ olarak hesaplanır ve tanımlayıcı bu ikili sayıların histogramını oluşturur.

Bu çalışmada LBP ile 59 öznitelik hesaplanmıştır.

3.3.2. Renk Dönüşümleri

Bilgisayarla görü alanında başlarda sadece gri seviye (grayscale) görsellere ait öznitelikler çalışmalara ışık tutsa da daha sonraları renkli görsellerin bu alana girmesiyle çalışmalar farklı bir boyut kazanmıştır. Dijital bir görüntü dokusu, bir görüntünün tamamında ya da seçilen bir bölgesindeki renk ve piksel yoğunluğu, verilerin uzamsal düzenlenmesi hususunda araştırmacılara bilgi sağlamaktadır (Stockman ve Shapiro, 2001). Bu nedenle araştırmacılar görsellerin sadece gri seviye öznitelikleri ile yetinmeyip renkli piksel özniteliklerini de dikkate almışlardır (Madiwalar ve Wyawahare, 2017; Suttapakti ve Bunpeng, 2019; Xian ve Ngadiran, 2021). Yapılan çalışmalarda, renk dokusu yoluyla gerçekleştirilen doku öznitelik çıkarımının sınıflama başarısında önemli bir artışa yol açtığı gözlemlenmiştir. Bununla birlikte elde edilen sayısal bir görüntünün, sayısal ortamda farklı renk uzayları bulunmaktadır. Yapılan çalışmalarda olduğu gibi bu çalışmada da farklı renk uzayları dikkate alınmıştır. Her bir veri için Red-Green-Blue (RGB) ve Hue-Saturation-Value (HSV) renk uzayları kullanılarak bu renk uzaylarının modelin başarısında bir fark yaratıp yaratmadığı incelenmiştir.

3.3.3. Geleneksel Sınıflandırıcılar

3.3.3.1. DVM (Destek Vektör Makineleri)

Destek Vektör Makineleri (Support Vector Machines-SVM), pek çok doku sınıflandırması problemi için kullanılmakta olan bir makine öğrenmesi (ML) metodudur. Özellikle çok sınıflı sınıflandırma problemleri için oldukça faydalıdır. SVM yüksek verilerle karşılaştığında genelleme yapmakta, doku özellik uzayında optimum hiper düzlem oluşturmaktadır (Memmedova, 2012).


3.3.3.2. Yapay Sinir Ağları (YSA)

Yapay sinir ağları (YSA), insan beyninin bilgiyi işleme biçimini simüle etmek için tasarlanmış, biyolojik olarak ilham alınmış bilgisayar programlarıdır. YSA'lar, verilerdeki kalıpları ve ilişkileri tespit ederek bilgilerini toplar ve programlamadan değil, deneyim yoluyla öğrenirler (veya eğitilirler). Bir YSA, nöral yapıyı oluşturan ve katmanlar halinde düzenlenen katsayılarla (ağırlıklar) bağlantılı yüzlerce tekil birimden, yapay nöronlardan veya işlem elemanlarından (Processing Element-PE) oluşur. Sinirsel hesaplamaların gücü,

bir ağdaki nöronları birbirine bağlamaktan gelmektedir. Her PE'nin ağırlıklı girişleri, aktarım işlevi ve bir çıkışı vardır. Bir sinir ağının davranışı, nöronlarının transfer fonksiyonları, öğrenme kuralı ve mimarinin kendisi tarafından belirlenir. Ağırlıklar ayarlanabilir parametrelerdir ve bu anlamda bir sinir ağı parametreleştirilmiş bir sistemdir. Girdilerin ağırlıklı toplamı, nöronun aktivasyonunu oluşturur (Agatonovic-Kustrin ve Beresford., 2000).

3.3.4. Önerilen Geleneksel Makine Öğrenme Modeli

Çalışmanın geleneksel tarafında, GLCM'ye dayalı özneliklerin SVM sınıflandırıcısı kullanılarak sınıflandırıldığı 8 sınıflı bir model önerilmektedir. Sıfırdan özgün BUFFALO-22 veri seti kullanılarak eğitilen model mimarisinin aşamaları Şekil 3.3'de sunulmuştur. Ham olarak elde edilen görsel veriler önce artırılmıştır. Artırılan veriler HSV renk uzayına dönüştürülerek farklı kanallara (H, S, V) ayrıştırılmıştır. Buna ek olarak gri seviye kanallar da kullanılmıştır. Elde edilen piksellerden GLCM kullanılarak öznelikler elde edilmiştir. Son olarak hesaplanan öznelikler SVM sınıflandırıcısı ile sınıflandırılmıştır.



Şekil 3.3. BUFFALO-22 veri seti kullanılarak eğitilen model mimarisinin aşamaları

3.4. Derin Öğrenme Analizi

3.4.1. Evrişimsel Sinir Ağları (CNN)

Evrişimsel Sinir Ağları (Convolutional Neural Networks-CNN) insan beyninden ilham alınarak tasarlanmış ve verilerdeki ayırt edici özellikleri kendi kendine öğrenebilen bir derin öğrenme modelidir (Hayıt, 2021).

Bir evrişimsel sinir ağı (CNN), derin öğrenme alanındaki en önemli ağlardan biridir. CNN, bilgisayar görüşü ve doğal dil işleme ve daha başka pek çok alanda etkileyici başarılar elde ettiğinden, son birkaç yılda hem endüstride hem de akademik çevrelerden büyük bir ilgi görmüştür (Li vd., 2022).

3.4.2. Transfer Öğrenimi

Transfer öğrenimi (Transfer Learning), daha önce öğrenilmiş olan ilgili bir görevden bilgi aktarımı yoluyla yeni bir görevdeki öğrenmenin iyileştirilmesidir. Çoğu makine öğrenimi algoritması, tek bir görevi ele almak için tasarlanırken, transfer öğrenimini kolaylaştıran algoritmaların geliştirilmesi, makine öğrenimi topluluğunda devam eden bir ilgi konusudur. Yaygın makine öğrenme algoritmaları geleneksel olarak yalıtılmış görevleri ele almaktadır. Transfer öğrenimi, bir veya daha fazla kaynak görevde öğrenilen bilgileri aktararak ve bunu ilgili bir hedef görevde öğrenmeyi geliştirmek için kullanarak geleneksel makine öğrenimini geliştirmeye çalışır (Olivas vd., 2009).

3.4.3. InceptionV3

InceptionV3 algoritmasının ilk versiyonu olan GoogleNet, Google firmasından Szegedy vd. (2015) tarafından oluşturulmuş bir derin öğrenme modelidir. Görüntü sınıflama üzerinde başarısı ilk versiyonda kanıtlanırsa da algoritma parametre sayısı ve hesaplama verimliliği açısından sonraları geliştirilmiştir. Szegedy vd. (2016) tarafından ortaya atılan bu geliştirilmiş versiyonlardan biri olan InceptionV3'ün diğer versiyonlara göre başarısı da aynı çalışmada kanıtlanmıştır. GoogleNet ya da InceptionV3, nesne tanıma ya da yüz tanıma gibi görevler için bazı çalışmalarda kullanılmıştır (Zabir vd., 2018; Lu vd., 2019; Jignesh Chowdary vd., 2020; Krishna Chaitanya ve Maragatham., 2021; Shoaib ve Sayed, 2022). InceptionV3, temelde görüntü sınıflama üzerine başarılı sayılsa da algoritmanın

YOLO gibi gerçek zamanlı nesne tanıma üzerine geliştirilen diğer derin öğrenme modelleriyle de karşılaştırılması gerekmektedir.

3.4.4. YOLOv5

YOLOv5, YOLO nesne algılama algoritmasının en gelişmiş algılama ağıdır. YOLO v3 ve YOLO v4 algoritmalarına dayalı olarak, algılama hızını artırmak için aritmetik küme yeniliği gerçekleştirilmiştir. YOLOv5, R-CNN algoritmasının hızını artırmak için bağlantı kutuları fikrini almıştır ve manuel olarak seçilen bağlantı kutuları terk edilmiştir. Daha iyi bir ön değer elde etmek için sınırlayıcı kutunun boyutları üzerinde K-ortalama kümelemesi aktif edilmiştir. 2020'de Jocher, YOLOv5 sürümünü yayınlamıştır (Zhang vd. 2022).

3.4.5. Önerilen Derin Öğrenme Modeli

Çalışmanın derin öğrenme tarafında, 8 sınıflı bir derin öğrenme metodu olarak BUFFALO-YOLOv5 metodu önerilmektedir. Sıfırdan özgün BUFFALO-22 veri seti kullanılarak eğitilen BUFFALO-YOLOv5 mimarisinin aşamaları gerçekleştirilmiştir.

Ham olarak elde edilen görsel veriler artırılarak ince ayarlanmış YOLOv5 algoritması ile eğitilmiştir. Eğitilen model üzerinde tanıma işlemi gerçekleştirilmiştir.

3.5. Performans Değerlendirme

Kullanılan modellerin performansları doğruluk, kesinlik, hassasiyet ve F1-Skor metrikleri kullanılarak belirlenmiştir. Kesinlik, hassasiyet ve F1-Skor ölçümleri, yüz tanıma gibi görüntü sınıflandırma görevlerinde modelin performansının farklı yönleri hakkında fikir sunmakta ve kullanılan modellerin etkinliklerini değerlendirmeye yardımcı olmaktadır. Performans ölçümleri, modelin tahminlerinin ayrıntılı bir dökümünü sağlayan karışıklık matrisi kullanılarak hesaplanmıştır. Karışıklık matrisi, modelin tahminlerini dört kategoriye ayırarak özetler: doğru pozitifler (TP), doğru negatifler (TN), yanlış pozitifler (FP) ve yanlış negatifler (FN). Bu değerler performans metriklerini aşağıdaki gibi hesaplamak için kullanılmıştır:

3.5.1. Doğruluk

Doğruluk, yüz tanıma problemlerinde sınıflandırma modellerinin performansını değerlendirmek için yaygın olarak kullanılan bir metriktir. Toplam örnek sayısı üzerinden doğru sınıflandırılmış örneklerin oranını hesaplayarak modelin tahminlerinin genel doğruluğunu ölçer. Yüksek doğruluk, modelin düşük yanlış sınıflandırma oranına sahip olduğunu ve hastalık seviyesini doğru bir şekilde tanımladığını gösterir.

3.5.2. Kesinlik

Kesinlik (pozitif tahmin değeri olarak da bilinir), model tarafından pozitif olarak tahmin edilen tüm örneklerden ($TP + FP$) doğru tanımlanmış pozitif örneklerin oranını ölçer.

3.5.3. Hassasiyet

Hassasiyet, veri kümesindeki tüm gerçek pozitif örnekler ($TP + FN$) arasından doğru tanımlanmış pozitif örneklerin oranını ölçer. Yüksek bir hassasiyet, modelin düşük bir FN oranına sahip olduğunu, yani nadiren doğru bir yüzü tanımlayamadığını gösterir.

3.5.4. F1-Skor

F1-Skor hem hassasiyeti hem de kesinliği tek bir metrikte birleştirir. Hem FP hem de FN'yi dikkate alarak modelin genel performansının dengeli bir ölçüsünü sağlar. Hassasiyet ve kesinliğin harmonik ortalamasıdır ve 0 ile 1 arasında değişir. Daha yüksek bir F1-Skoru, hassasiyet ve duyarlılık arasında daha iyi bir denge olduğunu gösterir (Hayıt, 2021).

4. BULGULAR VE TARTIŞMA

Bu tez çalışması kapsamında elde edilen BUFFALO-22 veri seti kullanılarak derin öğrenme gibi popüler modern görüntü sınıflama ve nesne algılama yöntemlerinin yanı sıra bir karşılaştırma sunmak ve geleneksel metotların performansını ortaya koymak amacıyla geleneksel yöntemler de kullanılmıştır. Dolayısı ile çalışmanın analizi geleneksel yaklaşımlar ve derin öğrenme olmak üzere iki aşamada ele alınmaktadır.

4.1. Geleneksel Makine Öğrenimine Dayalı Yüz Tanıma Bulguları

Çalışmada modern yöntemlere alternatif olarak geleneksel metotların bir çözüm sunup sunmayacağını belirlemek ve modern yöntemlerin başarısını kesin bir şekilde ortaya koymak amacıyla geleneksel yöntemlerden faydalanılmıştır. Bu bağlamda literatürde özellikle yüz tanıma veya nesne tanıma gibi görevlerde sıkça kullanılan istatistiksel öznitelik çıkarım metotları ve sınıflandırıcılar kullanılmıştır. Tüm analizler MATLAB yazılımı ile tamamlanmıştır.

Çalışmanın geleneksel tarafında amaç, sekiz manda üzerinden örnek bir veri kümesi oluşturularak mandaların yüzlerinin tanınmalarını sağlamak için en etkili algoritmayı bulmaktır. Sınıflandırıcının sağlamlığını değerlendirmek için, sonuçlardaki değişimleri gözlemlemek üzere farklı veri kümeleriyle değerlendirilmesi gerekir. Bu amaçla, rastgele örnekleme ile holdout validasyonu kullanılmıştır. BUFFALO-22 veri kümesi üç gruba ayrılmıştır: Eğitim (%70), Doğrulama (%20) ve Test (%10). Eğitim veri kümesi model eğitimi için, Doğrulama veri kümesi eğitim sürecinde modeli doğrulamak için ve Test veri kümesi de nihai modelin performansını değerlendirmek için kullanılmıştır. Bu süreç, tutarlı doğruluk tahminlerine olanak tanımakta ve modelin genelleme kabiliyetinin güvenilir bir şekilde değerlendirilmesini sağlamaktadır. Her bir sınıf için eğitim, doğrulama ve test verilerinin sayısı aşağıda verilmiştir (Tablo 4.1).

Tablo 4.1. Eğitim, doğrulama ve test grupları

Gruplar	1	2	3	4	5	6	7	8
Eğitim	350	350	350	350	350	350	350	350
Doğrulama	100	100	100	100	100	100	100	100
Test	50	50	50	50	50	50	50	50

Her bir renkli (RGB) manda görüntüsü HSV ve $L^*a^*b^*$ gibi farklı renk uzaylarına dönüştürülmüştür. Sonrasında, görüntüler her bir renk uzayı için renk uzaylarının farklı kanallarına ayrıştırılmıştır (örneğin, RGB için R, G, B). İkincil doku öznitelikleri, her bir renk kanalı ve bir gri seviye için GLCM ve LBP kullanılarak çıkarılmıştır. Toplam altı özellik seti geliştirilmiş ve doku özellikleriyle farklı sınıflandırıcılar eğitilerek değerlendirilmiştir. Bu noktada özellikle belirtmekte fayda vardır ki, bulgulara göre $L^*a^*b^*$ renk uzayına dayalı sınıflandırma performansı RGB ve HSV renk uzaylarına göre oldukça düşük hesaplanmıştır. Dolayısıyla çalışmanın bulgular kısmında sadece RGB ve HSV renk uzaylarına dayalı sonuçlar sergilenmiştir. Özellik setlerinin detayları Tablo 4.2’de verilmiştir.

Tablo 4.2. Öznitelik seti verileri

Öznitelik Seti	Renk Uzayı	Öznitelik Çıkarımı	Renk Kanalları	Toplam Öznitelik Sayıları (Girdiler)
GLCM-RGB	RGB	GLCM (9 öznitelik)	R+G+B+Graylevel	4x9=36 öznitelik
GLCM-HSV	HSV		H+S+V+Graylevel	
LBP-RGB	RGB	LBP (59 öznitelik)	R+G+B+Graylevel	4x59=236 öznitelik
LBP-HSV	HSV		R+G+B+Graylevel	

Elde edilen yapısal öznitelik veri setleri SVM sınıflandırıcısı kullanılarak eğitilmiştir. Eğitilen modeller arasında LBP-HSV öznitelik veri seti kullanılarak eğitilen model %88,3’lük doğrulukla en iyi performansı elde etmiştir. Tablo 4.3’de modeller, ilgili öznitelik veri setlerini ve performanslarını göstermektedir. Tablo, HSV renk uzayının her iki özellik çıkarma yönteminde de daha iyi performans gösterdiğini kanıtlamaktadır. HSV ile elde edilen doğruluk oranı, RGB dışındaki renk uzayları kullanılarak daha iyi performans elde edilebileceğini göstermiştir.

Tablo 4.3. Doğrulama doğruluk oranları (%)


Öznitelik Setleri	Doğruluk
GLCM-RGB	81.9
GLCM-HSV	85.6
LBP-RGB	80.6
LBP-HSV	88.3

Günümüzde makine öğrenmesi modellerinin eğitim sırasında hesaplanan doğrulama doğruluğu, modelin başarısını ve probleme genellenebilirliğini belirlemede yetersiz görülmekte ve eleştirilmektedir. Bu nedenle, her bir model, modellerin eğitim sırasında karşılaşmadığı 400 manda görüntüsü ile test edilmiştir. Test sonuçları, tüm modellerin test performansının doğrulama performansına yakın olduğunu göstermektedir. Bu da modellerin probleme iyi uyum sağladığını göstermektedir. En iyi ortalama doğruluk performansına sahip LBP-HSV modeli için test doğruluğunun neredeyse ortalama doğruluk kadar başarılı olduğu hesaplanmıştır (%87,7). Test veri seti için ortalama doğruluk oranları Tablo 4.4’de verilmiştir.

Tablo 4.4. Test doğruluk oranları (%)

Öznitelik Setleri	Doğruluk
GLCM-RGB	84.7
GLCM-HSV	87.2
LBP-RGB	84.2
LBP-HSV	87.7

Şekil 4.1’de görüldüğü gibi her bir öznitelik veri kümesi için en başarılı modeller olan GLCM-HSV (Şekil 4.1.solda) ve LBP-HSV (şekil 4.1.sağda) modelleri için karışıklık (hata) matrislerini içermektedir. Karışıklık matrisi, modellerin her sınıf için nasıl performans gösterdiğini göstermektedir. Burada satırlara karşılık gelen 0-7 rakamları her bir mandaya ait numaraları temsil etmektedir.



Şekil 4.1. GLCM-HSV ve LBP-HSV öznitelik seti üzerinde eğitilen modeller için karışıklık matrisleri, solda GLCM-HSV modeli ve sağda LBP-HSV modeli

Tüm analizler için karışıklık matrisleri çizilmiş ve karışıklık matrisleri kullanılarak kesinlik, hassasiyet ve F1-Skor metrikleri de hesaplanmıştır. Tüm öznitelik setleri üzerinde en iyi sınıflandırma performansına sahip GLCM-HSV ve LBP-HSV modelleri için performans metrikleri Tablo 4.5’de gösterilmiştir. Tablodan, LBP-HSV özellik seti ile eğitilen modelin GLCM-HSV modeline göre daha iyi performans gösterdiği görülmektedir. Bununla birlikte sınıf bazı performanslara dikkat edildiğinde en iyi modelin sırasıyla 1, 5 ve 7 nolu mandaların yüzlerini iyi derecede sınıflandırdığı söylenebilir.

Tablo 4.5. Modellerin diğer ölçütler dikkate alınarak karşılaştırmalı performansları

Manda	GLCM-HSV			LBP-HSV		
	Kesinlik	Duyarlık	F1-Skor	Kesinlik	Duyarlık	F1-Skor
0	0.64	0.87	0.74	0.77	0.88	0.82
1	0.91	0.85	0.88	0.92	0.96	0.94
2	0.89	0.81	0.85	0.85	0.85	0.85
3	0.85	0.90	0.87	0.88	0.84	0.86
4	0.87	0.82	0.85	0.93	0.78	0.85
5	1.0	1.0	1.0	0.89	0.95	0.92
6	0.88	0.81	0.84	0.88	0.84	0.86
7	0.95	0.89	0.92	0.89	0.93	0.91

Geleneksel analiz bulgularına göre modellerin vasat olduğu düşünülse de literatürel açıdan kayda değer bir başarı elde edildiği söylenebilir.


4.2. Derin Öğrenme Analiz Bulguları

4.2.1. InceptionV3

Yüz tanıma görevlerinde genellikle yüz tanımanın anlık olarak sağlanması beklenmektedir. Nihayetinde yüz tanıma görevleri de görüntü sınıflandırmanın bir alt görevi olarak değerlendirilebilir. Çalışmanın bu aşamasında manda yüz görüntülerinin anlık olarak değerlendirilmesini sağlayan derin öğrenme tabanlı önerilen YOLOv5 modeline alternatif olarak diğer CNN görüntü sınıflandırma modellerinden InceptionV3 işe koşulmuş ve bulguları paylaşılmıştır. Tüm analizler MATLAB yazılımı ile tamamlanmıştır.


Veri artırma ile oluşturulan 4000 görüntüden oluşan nihai dataset geleneksel tarafta ve YOLOv5’te olduğu gibi 70:20:10 (eğitim, doğrulama ve test) oranlarında kullanılmıştır. Deneyler esnasında InceptionV3 önceden eğitilmiş bir model olarak BUFFALO-22 veri

seti ile eğitilerek doğrulanmıştır (Şekil 4.2). InceptionV3 modeli %98,37'lik bir doğrulama başarısı elde etmiştir.




Şekil 4.2. InceptionV3'ün 20 döngü için eğitim süreç grafiği

InceptionV3 modeli için hem eğitim hem de doğrulama doğruluk grafikleri çizilmiştir (Şekil 4.3). Eğitim sırasında eğitim ve doğrulama doğruluğunun arttığı gözlemlenmiştir.



Şekil 4.3. InceptionV3 modeli 20 döngü (epoch) için eğitilmiş ve her döngüden sonra eğitim-doğrulama doğrulukları


InceptionV3 modeli 20 döngü (epoch) için eğitilmiş ve her döngüden sonra eğitim-doğrulama kayıp değerleri grafiği oluşturulmuş ve sunulmuştur (Şekil 4.4). Eğitim sırasında eğitim ve doğrulama kayıplarının azaldığı gözlemlenmiştir.



Şekil 4.4. InceptionV3 modeli 20 döngüsü (epoch) eğitim-doğrulama kayıp değerleri

InceptionV3, eğitim sürecinde karşılaşmadığı 400 (%10'luk test kümesi) ile test edilmiştir. Modelin test performansının doğrulama performansına yakın bir sonuç verdiği görülmüştür. Bu da modelin probleme iyi bir şekilde genelleştirildiğini göstermiştir. InceptionV3 modeli için test doğruluğu performansı doğrulama doğruluğu ile neredeyse aynıdır (0.9850).

InceptionV3 modeli için karışıklık matrisi Şekil 4.5'de sunulmuştur. Modelin her bir sınıf için performansı karışıklık matrisinde açıkça görülmektedir. Buna göre model ortalama her bi sınıfı %100'e yakın bir başarıyla sınıflandırabilmiştir.



Şekil 4.5. InceptionV3 modeli için karışıklık (hata) matrisi

Son olarak, geleneksel modellerde olduğu gibi InceptionV3 modelinin karışıklık matrisi kullanılarak kesinlik, duyarlılık ve F1-Skor metrikleri de hesaplanmıştır. Bu metrikler de önceden eğitilmiş bir derin öğrenme modeli olarak InceptionV3'ün manda yüz görüntülerini başarıyla sınıflandırabildiğini desteklemiştir. InceptionV3'ün her bir sınıf için performansı Tablo 4.6 üzerinde ayrıntılı olarak sunulmuştur. Tabloya göre modelin en başarısız olduğu sınıfın 1 numaralı manda olduğu söylenebilir.

Tablo 4.6. InceptionV3'ün diğer ölçütler dikkate alınarak performans sonuçları

Manda	Kesinlik	Duyarlık	F1-Skor
0	0.96	1.0	0.98
1	0.98	0.92	0.95
2	1.0	1.0	1.0
3	0.98	1.0	0.99
4	1.0	0.98	0.99
5	1.0	1.0	1.0
6	0.96	1.0	0.98
7	1.0	0.98	0.99

4.2.2. YOLOv5

YOLO, gerçek zamanlı bir nesne algılama algoritmasıdır. Yüz tespit algoritmalarına kıyasla hız ve doğruluk oranının ihtiyaçları karşılamaından dolayı YOLO daha çok tercih edilmektedir. YOLO'nun diğer algoritmalarından ayrılan özelliği hızıdır. YOLO algoritmasının hızlı olmasının nedeni görüntüyü tek seferde sinir ağından geçirerek görüntüdeki tüm nesnelerin sınıf ve koordinatlarını tespit edebilmesidir. Bunun yaparken görüntüyü NxN'lik ızgaralara ayırmaktadır. Her ızgaranın kendi içerisinde işlem yapılmaktadır. YOLO algoritmasının 5. versiyonu olan YOLOv5 algoritmasının GPU performansının alt modellere nazaran daha başarılı olduğu bilindiğinden bu çalışmada YOLOv5 kullanılmıştır.

Ortalama Kesinlik (Average Precision: AP) ve Ortalama Kesinliklerin Ortalaması (Mean average precions: mAP) metrikleri özellikle, yüz tanıma gibi anlık nesne tespit görevlerinde diğer metrikler gibi sık kullanılan metriklerdir. Bu nedenle çalışmanın performans değerlendirme başlığı altında verilen metriklere ek olarak bu ölçütlerden de faydalanılmıştır.


Bu çalışmada BUFFALO-22 veri seti kullanılarak YOLOv5x6 modeli eğitilmiştir. Model eğitiminde hiperparametrelerden batch değeri 16 ve epoch değeri 150 olarak belirlenmiştir. İlk 10 epoch ve son 10 epoch verileri Şekil 4.6 üzerinde gösterilmiştir. İlk epoch ve son epoch arasındaki kesinlik (precision), hassasiyet (recall) ve mAP değerlerinde artış görülmektedir.

epoch	metrics/precision	metrics/recall	metrics/mAP_0.5
0	0.12727	0.71596	0.15635
1	0.2251	0.68706	0.31847
2	0.34601	0.65322	0.44965
3	0.59211	0.66742	0.69733
4	0.71052	0.73865	0.8094
5	0.81745	0.79245	0.88347
6	0.76474	0.71725	0.82925
7	0.87744	0.86251	0.92679
8	0.87689	0.86096	0.93217
9	0.8879	0.87619	0.95355
10	0.95695	0.91713	0.96897
139	0.98903	0.99327	0.99389
140	0.98911	0.99325	0.99391
141	0.98921	0.99323	0.9939
142	0.98925	0.99323	0.99392
143	0.98923	0.99323	0.99391
144	0.98924	0.99323	0.99389
145	0.98917	0.99326	0.99391
146	0.9892	0.99326	0.9939
147	0.98922	0.99327	0.9939
148	0.98927	0.99328	0.99391
149	0.98927	0.99328	0.99391

Şekil 4.6. İlk 10 ve son 10 epoch verileri

ROC eğrileri (alıcı işletim karakteristik eğrileri), yüz tanıma modellerinin performanslarının belirlenmesinde önemli bir araç olarak değerlendirilmektedir. ROC eğrisi, modelin gerçek pozitif oranı (TPR) ile yanlış pozitif oranı (FPR) arasındaki ilişkiyi gösterir. TPR, sınıflandırıcının "pozitif" gözlemler için "pozitif" tahmin etme hızıdır. FPR, sınıflandırıcının gerçekte "negatif" olan gözlemler için "pozitif" tahmin etme hızıdır. Mükemmel bir sınıflandırıcının TPR'si 1 ve FPR'si 0 olacaktır. Şekil 4.7 üzerinde sırasıyla kesinlik (precision), hassasiyet (recall) ve mAP değerlerinin ROC eğrilerinin grafiksel

gösterimi sunulmaktadır. Grafiğe göre TPR değerlerinin 1'e oldukça yakın oldukları gözlemlenmektedir.




Şekil 4.7. Soldan sağa sırasıyla kesinlik (precision), hassasiyet (recall) ve mAP grafikleri

Jaccard benzerlik katsayısı olarak da bilinen Intersection over union (IoU) mAP gibi nesne tanıma görevlerinde en yaygın kullanılan metriklerdendir. Canlı olarak tespit edilen manda yüzlerine ait anlık değerlendirme görselleri (Şekil 4.8) üzerinde IoU değerleri dikkate alındığında YOLOv5'in başarılı bir performans sunduğu savunulabilir.




Şekil 4.8. YOLOv5 modelinin manda yüz görüntüleri üzerinde anlık tespit durumları

Modelin 5 numaralı manda yüzü görselleri üzerinde anlık tespit reaksiyonları Şekil 4.9 üzerinde sunulmaktadır.



Şekil 4.9. YOLOv5 modelinin 5 numaralı manda yüz görüntüleri üzerinde anlık tespit durumları

YOLOv5'in performansının belirlenebilmesi için diğer modellerde olduğu gibi karışıklık matrisinden faydalanılmıştır. Bu matrise göre TP (True Positive) değeri 0.98, FP (False Positive) değeri 1.00, FN (False Negative) değeri 0.02, TN (True Negative) değeri 0 olarak belirlenmiştir. Karışıklık matrisi kullanılarak kesinlik, hassasiyet ve F1-Skor ölçütleri de hesaplanmıştır. Modelin karışıklık matrisi Şekil 4.10 üzerinde sunulmuştur.



Şekil 4.10. YOLOv5 modeline ait karışıklık matrisi

4.3. Tartışma

Çalışmada, mandanın yüz görüntülerinden oluşan BUFFALO-22 veri seti kullanılarak hem geleneksel yöntemlerin hem de modern yöntemlerin (LBP-HSV, InceptionV3 ve YOLOv5) kullanımıyla elde edilen sonuçlar karşılaştırılmıştır. Geleneksel yöntemlerle, görseller önceden belirlenmiş öznitelik çıkarım teknikleriyle işlenmiş ve Destek Vektör Makinesi kullanılarak sınıflandırılmıştır. LBP-HSV modeli ile yapılan testlerde %87,7'lik bir doğruluk elde edilmiştir. Modern yöntemler arasında önceden eğitilmiş InceptionV3 ve YOLOv5 modelleri kullanılmıştır. Deneysel sonuçlar, hem InceptionV3'ün %98,5'lik ortalama test doğruluğu ile yüz tespitinde başarılı olduğunu, hem de YOLOv5'in eğitimi sonucunda 0.98 kesinlik, 0.99 hassasiyet ve 0.99 mAP değeri elde edildiğini göstermiştir.

Yüz tanıma yönteminin hayvanlarda kullanımı hakkında yapılan araştırmalar sınırlı olmasına rağmen, bu alanda başarılı çalışmalar bulunmaktadır (Burghardt ve Campbell, 2007; Kakıcı, 2008). Örneğin, Kumar vd. (2015), sığır sınıflandırması için yüz tanıma biyometrisini kullanarak yaptıkları çalışmada, sığırların kimliklerini yüksek doğruluk oranıyla tanımlamışlardır. Khan vd. (2020) ise kendi sınıflandırma modellerini oluşturmak için yüksek doğruluk oranları elde etmişlerdir. Bu çalışmada, büyük ölçekte görüntü

özelliklerini çıkaran ve analiz eden tam bağlantılı Çift Derin Evrişimli Sinir Ağı (DCNN) kullanılmıştır.

Li vd. (2020) tarafından yapılan bir çalışmada, Transfer Öğrenme yaklaşımı ve önceden eğitilmiş ağırlıklar kullanılarak panda ve geyiklerin kafes arkasındaki görüntülerinin tespit edilmesinde etkili bir yöntem olan M2Det kullanılmıştır. Kumar vd. (2018) sığırların burun deseni görüntülerini kullanarak makine öğrenme teknikleriyle sığırları %99,89 doğrulukla tanımlamayı başarmışlardır. Dandıl vd. (2019) ise sığırların yüzlerini tanımak için Daha Hızlı Bölgesel-Evrişimsel Sinir Ağları (Faster R-CNN) kullanarak başarılı bir sınıflandırma elde etmişlerdir.

McLennan ve Mahmoud (2019), koyunlardaki acı ve ağrının derin öğrenme ile yüzlerinden okunabilmesi üzerine bir çalışma yapmışlardır. Xu vd. (2020) ise quadcopter kullanarak geniş meralar ve besi yerlerinde sığır sayımı için Mask R-CNN'nin uygulamasını göstermişlerdir, bu çalışmanın deneysel sonuçları çevrimdışı güvenilir bir şekilde performans gösterme potansiyelini ortaya koymuştur.

Dutta'nın (2021) çalışmasında, koyunların ırklarına göre sınıflandırılması amaçlanmıştır ve elde edilen doğruluk oranları dikkat çekicidir. Fuentes vd. (2020) ise süt sığırlarında RGBD kameralar kullanarak yapılan bir araştırmada, invazif olmayan bilgisayarlı görme yöntemleri ve makine öğrenimi modellemesi kullanarak süt verimliliği, süt yağı ve süt proteini tahmin etmede yüksek doğruluk elde etmişlerdir (%0,96).

Bu çalışmalarda geliştirilen sistemlerin çoğu, insanoğluna benzer şekilde veriden probleme özgü ayırt edici öznitelikleri otomatik olarak öğrenebilen ve sınıflandırabilen ML yaklaşımlarına dayanmaktadır. Bununla birlikte, benzer yaklaşımların büyük miktarda etiketli eğitim verisine ve yüksek performanslı donanımlar gibi önemli hesaplama kaynaklarına ihtiyaç duyması gibi dikkate alınması gereken bazı sınırlamaları da bulunmaktadır. Ayrıca bu sistemler uzmanlık gerektirirler ve özellikle büyük veri kümeleri veya karmaşık mimariler için zaman alıcı olabilmektedirler. Çeşitli senaryolarda ML yaklaşımlarını kullanmanın uygulanabilirliğini ve potansiyel zorluklarını değerlendirirken bu sınırlamaları göz önünde bulundurmak çok önemlidir.

Son olarak, ilgili çalışmaların ve bu makalenin sonuçları Tablo 4.7'de sunulmuştur ve bu çalışmada olduğu gibi ML ve DL modellerinin sınıflandırma performansına katkısı açıkça görülmektedir.

Tablo 4.7. Benzer yaklaşımların kullanıldığı ilgili çalışmaların özeti

Çalışma	Hayvan Türü	Performans Ölçütü	Kullanılan Model	Sonuç
Önerilen çalışma	Manda	mAP	YOLOv5	0.99
Kumar vd. (2015)	Sığır	Doğruluk	Çeşitli ML	%92,5
Kumar vd. (2018)	Sığır	Doğruluk	Derin İnanç Ağı	%99,89
Dandıl vd. (2019)	Sığır	Doğruluk	Faster R-CNN	%98,44
Khan vd. (2020)	Çeşitli	Doğruluk	DCNN	%92
Li vd. (2020)	Panda ve geyik	mAP	M2Det	0.9819
Xu vd. (2020)	Sığır	Doğruluk	Mask R-CNN	%94
Fuentes vd. (2020)	Sığır	Doğruluk	Çeşitli ML	%96
Dutta (2021)	Koyun	Doğruluk	5 Katmanlı CNN	%99,97

Bu çalışmalardan da görüleceği gibi, her geçen gün artan teknolojik gelişmeler ışığında yüz tanıma yöntemlerinin hayvanlarda çeşitli uygulamalarının mümkün olduğunu ve bu teknolojilerin hayvanların izlenmesi, tanımlanması ve sağlığının değerlendirilmesi gibi alanlarda etkili bir araç olabileceğini göstermektedir.

5. SONUÇ VE ÖNERİLER

Bu çalışmada manda yüz görüntüleri kullanılarak manda yüzlerinin tespit edilebilirliği araştırılmıştır. Çalışma kapsamında oluşturulan özgün BUFFALO-22 veri seti literatüre kazandırılmıştır. Modern bir yöntem olarak derin öğrenme yaklaşımları işe koşulmuş ve performansları değerlendirilmiştir. Toplamda sekiz sınıflı (manda) yüz tanıma görevi ayrıca geleneksel yöntemler de kullanılarak değerlendirilmiştir.

Geleneksel tarafta yaygın kullanılan öznitelik çıkarım metotları ve SVM sınıflandırıcısı kullanılarak kayda değer bir başarı elde edilmiştir. Bununla birlikte modern bir yöntem olarak derin öğrenme yaklaşımlarının performansları da dikkat çekici olmuştur. Önceden eğitilmiş CNN algoritmalarından InceptionV3 manda yüz görsellerini başarılı bir derecede sınıflandırabilmiştir.

Diğer yandan anlık yüz tanıma problemleri için yaygın olarak kullanılan bir derin öğrenme modeli olan YOLO algoritmasının beşinci versiyonu olan YOLOv5 kullanılmış ve mAP, kesinlik, hassasiyet ve F1-Skor metrikleri dikkate alındığında modelin manda yüzlerini başarılı bir seviyede tespit edebildiği kanıtlanmıştır. Doğruluk ve kayıp grafikleri karşılaştırıldığında başta YOLOv5 olmak üzere önceden eğitilmiş derin öğrenme modellerinin manda yüzlerinin tespit edilmesinde başarılı bir şekilde rol üstlenebilecekleri görülmektedir. Bu çalışma, yapay zekâ destekli yüz tanıma teknolojilerinin hayvancılık sektöründe büyük potansiyel taşıdığını ve bu teknolojilerin çiftçilere önemli avantajlar sağlayabileceğini göstermektedir. Yüz tanıma sistemlerinin hayvanlarda bireysel tanımlama, sağlık izleme, hastalık teşhisi ve genetik analiz gibi çeşitli alanlarda kullanılabilirliği, çiftliklerin daha akıllı ve verimli hale gelmesine olanak tanımaktadır. Gelecek yıllarda yapay zekâ teknolojilerindeki hızlı gelişmelerle birlikte, bu alandaki yeniliklerin hayvancılık sektöründeki uygulamalarını daha da genişletmek mümkün olacaktır. Bu teknolojilerin yaygınlaşması, yetiştiricilerin hayvanlarını daha etkili bir şekilde yönetmelerine, hastalıkları erken teşhis etmelerine ve genel olarak çiftlik verimliliğini artırmalarına yardımcı olabilir. Ayrıca, hayvan refahını ve sürdürülebilirliği iyileştirmek adına yapılan bu çalışmalar, tarım endüstrisine önemli katkılar sağlayarak geleceğin çiftliklerine yön verebilir.

Mandalar, doğaları gereği agresif davranışlar sergileyebilecekleri için yaklaşmak, kulak küpelerini okumak veya müdahale etmek oldukça zor olmaktadır. Mevcut kulak küpelerinin okunamaması, düşmesi ve takma sırasındaki saldırgan davranışların azaltılması

amacıyla yapay zekâ teknikleri ile tanımlanmaları büyük önem taşır. Özellikle yüz tanıma teknolojisi, hayvanların kimlik bilgilerini (pedigri, süt ve üreme bilgileri vb.) belirlemek için yaklaşımdan kullanılabilir ve gerekli müdahaleler yapılabilir.

Çalışmamız, elde edilen verilere dayalı olarak manda yüz tanıma modellerinin geliştirilmesine yönelik bir adım atmıştır. Bu sayede hassas tarım teknolojileri (PLF) uygulamak için zemin oluşturulmuş ve literatüre kazandırılmıştır. Özellikle seçtiğimiz yöntemle mandalar üzerinde yapılan çalışmaların sınırlı olması ve önerilen modelin minimum zaman maliyeti, düşük hata oranı ve yüksek doğruluk değeri sunması, çalışmamızı özgün hale getirmektedir.





6. KAYNAKLAR

- Aerts, H.J., Velazquez, E.R., Leijenaar, R.T., Parmar, C., Grossmann, P., Carvalho, S., ... & Lambin, P. (2014). Decoding tumour phenotype by noninvasive imaging using a quantitative radiomics approach. *Nature Communications*, 5(1), 4006.
- Agatonovic-Kustrin, S. & Beresford, R. (2000). Basic concepts of artificial neural network (ANN) modeling and its application in pharmaceutical research. *Journal of Pharmaceutical and Biomedical Analysis*, 22(5), 717-727.
- Akman, N. (1997). Hayvan Islahı. Hayvan Yetiştirme (Yetiştiricilik).(Editör: M. Ertuğrul), Baran Ofset, Ankara. S, 35-79.
- Altay, F. & Turhal, K. (2011). Bilecik İlindeki Tarımsal Mekanizasyonun Durumu ve Çözüm Önerileri. 6 th International Advanced Technologies Symposium (IATS'11), 16-18 May 2011, Elazığ.
- Aslan, D. (2004). Beden algısı ile ilgili sorunların yaratabileceği beslenme sorunları. *Sürekli Tıp Eğitimi Dergisi*, 13(9), 326-329.
- Assefa, D., Keller, H., Ménard, C., Laperriere, N., Ferrari, R. J. & Yeung, I. (2010). Robust texture features for response monitoring of glioblastoma multiforme on-weighted and-FLAIR MR images: A preliminary investigation in terms of identification and segmentation, *Medical Physics*, 37(4), 1722-1736.
- Atasever, S. & Erdem, H. (2008). Manda yetiştiriciliği ve Türkiye'deki geleceği. *Anadolu Tarım Bilimleri Dergisi*, 23(1), 59-64.
- Awad, A.I., Hassanien, A.E. & Zawbaa, H.M. (2013). A cattle identification approach using live captured muzzle print images. In *International Conference on Security of Information and Communication Networks* (pp. 143-152). Berlin, Heidelberg.
- Awad, A.I. (2016). From classical methods to animal biometrics: A review on cattle identification and tracking. *Computers and Electronics in Agriculture*, 123, 423-435.
- Aydın, A. (2007). Hayvanların Kimliklendirilmesi ve Kayıt Altına Alınmasının Göreceli Karşılaştırılması, İzlenebilirlik. Tarım ve Köyişleri Bakanlığı, Dış İlişkiler ve Avrupa Birliği Koordinasyon Dairesi Başkanlığı. AB Uzmanlık Tezi, Ankara.

- Bao, J. & Xie, Q. (2022). Artificial intelligence in animal farming: A systematic literature review. *Journal of Cleaner Production*, 331, 129956.
- Basheer, I.A. & Hajmeer, M. (2000). Artificial neural networks: fundamentals, computing, design, and application. *Journal of Microbiological Methods*, 43(1), 3-31.
- Bayramoğlu, Z., Tekin, M., & Ağızan, K. (2018). Türkiye’de biyoekonomi girişimciliğinin tarımdaki önemi. *Kahramanmaraş Sütçü İmam Üniversitesi Tarım ve Doğa Dergisi*, 21, 227-236.
- Baysal, A. (1996). Sağlıklı beslenme ve Akdeniz diyeti. *Beslenme ve Diyet Dergisi*, 25(1), 21-29.
- Biçgi, M. (2022). Nesne Tespit Algoritması (YOLOv4 Algoritması) ile Patates Böceğinin (*Leptinotarsa decemlineata*) (Say) Patates Bitkisi Üzerinde Saptanması ve Populasyon İzleme Olanakları, Yüksek Lisans Tezi, Isparta Uygulamalı Bilimler Üniversitesi Lisansüstü Eğitim Enstitüsü, Isparta.
- Bugge, C.E., Burkhardt, J., Dugstad, K.S., Enger, T.B., Kasprzycka, M., Kleinauskas, A., ... & Vetlesen, S. (2011). Biometric methods of animal identification. Course notes, Laboratory Animal Science at the Norwegian School of Veterinary Science, 1-6.
- Buchanan, B.G. (2006). A (Very) Brief History of Artificial Intelligence, *AI Magazine*, 26(4), 53-60.
- Burghardt, T., & Campbell, N. (2007). Individual animal identification using visual biometrics on deformable coat patterns. In *International Conference on Computer Vision Systems: Proceedings*.
- Burghardt, T. (2008). Visual animal biometrics: automatic detection and individual identification by coat pattern. PhD thesis, University of Bristol, UK.
- Chen, L. J., Cui, L.Y., Xing, L. & Han, L.J., (2008). Prediction of the nutrient content in dairy manure using artificial neural network modeling. *Journal of Dairy Science*, 91(12), 4822-4829.
- Chen, H., Chen, Z. & Yu, H. (2023). Enhanced YOLOv5: An efficient road object detection method. *Sensors*, 23(20), 8355.
- Chou, J.S., Ho, C.C. & Hoang, H.S. (2018). Determining quality of water in reservoir using machine learning. *Ecological Informatics*, 44, 57-75.

- Çeçen, Ş. (2023). Derin Öğrenme Teknikleri Kullanılarak Ratlarda Östrus Dönemlerinin YOLOv5 Modeli ile Sınıflandırılması, Yüksek Lisans Tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elâzığ.
- Çelikyürek, H. & Karakuş, K. (2017). Hayvansal üretimde biyometrik kimliklendirme ve kayıt. Yüzüncü Yıl Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 22(2), 211-218.
- Çelikyürek, H., Karakuş, K., Dellal, G. & Aygün, T. (2018). Ekolojik hayvancılıkta biyometrik kimliklendirmenin kullanılabilirliği. Hayvan Bilimi ve Ürünleri Dergisi, (1), 36-44.
- Dandıl, E., Turkan, M., Boğa M. & Çevik, K.K. (2019). Daha hızlı bölgesel-evrimsel sınır ağları ile sığır yüzlerinin tanınması. Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Dergisi, 6, 177-189.
- De Siqueira, F.R., Schwartz, W.R. & Pedrini, H. (2013). Multi-scale gray level co-occurrence matrices for texture description, Neurocomputing, 120, 336-345.
- Demir, B. (2013). Mersin İlinin tarımda teknoloji kullanım projeksiyonu. Alınteri Ziraat Bilimler Dergisi, 24(1), 29-34.
- Demir, Ü., Kula N., Uğurlu, B. (2021). Tarımda yapay zekâ kullanımına yönelik karar destek modeli önerisi: domates zararlısı tespiti örneği. Lapseki Meslek Yüksekokulu Uygulamalı Araştırmalar Dergisi, 2(4), 91-108.
- Demirci, M., Yüksel, A. N. & Soysal, M.İ. (1991). Memeden mamül maddeye süt. Hasad Yayıncılık. Hayvancılık Serisi, 1, 103-112.
- Demiryürek, K. (2004). Dünya ve Türkiye’de organik tarım. Harran Üniversitesi Ziraat Fakültesi Dergisi, 8(3/4), 63-71.
- Dutta, P. (2021). A deep learning approach for animal breed classification-sheep. International Journal for Research in Applied Science and Engineering Technology, 9(5), 10-22214.
- El Naqa, I. & Murphy, M.J. (2015). What is machine learning?. Springer International Publishing. 3-11
- Ermetin, O. (2017). Husbandry and sustainability of water buffaloes in Turkey. Turkish Journal of Agriculture-Food Science and Technology, 5(12), 1673-1682.

- Ermetin, O. (2020) KOP bölgesinde manda yetiştiriciliği ve önemi. Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü. Dergisi. 3(2), 164-171.
- Ermetin, O. (2021). Precision livestock farming: potential use in water buffalo (*Bubalus bubalis*) operations. Anim. Sci. Pap. Rep. 39, 19-30.
- FAO, 2022. <https://www.fao.org/faostat/en/#data/QCL> (Erişim Tarihi 15.07. 2022).
- Fuentes, S., Gonzalez Viejo, C., Cullen, B., Tongson, E., Chauhan, S.S., & Dunshea, F.R. (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.
- Fukushima, K. (1980). Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. Biological Cybernetics, 36(4), 193-202.
- Gündüz, M.Ş. (2023). Gerçek Zamanlı Videolardan Kalabalık ve Sosyal Mesafe Tespiti için YOLO Algoritmalarının Performans Analizi: Covid-19 Uygulaması. Yüksek Lisans Tezi, Iğdır Üniversitesi, Lisansüstü Eğitim Enstitüsü, Iğdır.
- Gürel, Z., & Aslan, D. (2019). Halk sağlığı bakış açısıyla gıda kaynaklı krizler ve önleme yaklaşımları. Türk Hijyen ve Deneysel Biyoloji Dergisi, 76(3), 361-376.
- Hamet, P & Tremblay, J. (2017). Artificial intelligence in medicine. Metabolism, 69, S36-S40.
- Haralick, R.M., Shanmugam, K. & Dinstein, I.H. (1973). Textural features for image classification, IEEE Transactions on systems, man, and cybernetics, (6), 610-621.
- Haralick, R.M. (1979). Statistical and structural approaches to texture. Proceedings of the IEEE, 67(5), 786-804.
- Hayit, T. (2021). Buğdayda Sarı Pas (*Puccinia Striiformis*) Hastalığının Değerlendirilmesi İçin Görüntü İşleme Teknikleri Kullanılarak Bir Karar Destek Sisteminin Geliştirilmesi. Doktora Tezi. Kırıkkale Üniversitesi Fen Bilimler Enstitüsü. Kırıkkale.
- Hayit, T., Erbay, H., Varçın, F., Hayit, F., & Akci, N. (2021). Determination of the severity level of yellow rust disease in wheat by using convolutional neural networks. Journal of Plant Pathology, 103(3), 923-934.

- Hayıt, T., Çınarer, G. (2022). X-Ray görüntülerini kullanarak GLCM ve Derin Özniteliklerin birleşimine dayalı Covid-19 sınıflandırılması, İnönü Üniversitesi Sağlık Hizmetleri Meslek Yüksek Okulu Dergisi, 10(1), 313-325.
- Hayıt, T., Erbay, H., Varçın, F., Hayıt, F., & Akci, N. (2023). The classification of wheat yellow rust disease based on a combination of textural and deep features. *Multimedia Tools and Applications*, 1-19.
- Hekimoğlu B. & Altindeğer M. (2006). Tarımın ve tarımsal göstergelerin ülkemizdeki ve Samsun ilindeki gelişim seyri. Samsun Valiliği Tarım İl Müdürlüğü Strateji 53 Geliştirme Birimi, 1-9
- Hertz, J.A. (2018). *Introduction to the Theory of Neural Computation*. CRC Press. Addison Wesley.
- Hogeveen, H., Noordhuizen-Stassen, E.N., Schreinemakers, J.F. & Brand, A. (1991). Development of an integrated knowledge-based system for management support on dairy farms. *Journal of Dairy Science*, 74(12), 4377-4384.
- Hornik, K. (1991). Approximation capabilities of multilayer feedforward networks. *Neural Networks*, 4(2), 251-257.
- Hubel, D.H. & Wiesel, T.N. (1968). Receptive fields and functional architecture of monkey striate cortex. *The Journal of Physiology*, 195(1), 215-243.
- Humeau-Heurtier, A. (2019). Texture feature extraction methods: A survey. *IEEE Access*, 7, 8975-9000.
- Jignesh Chowdary, G., Pun, N. S., Sonbhadra, S. K., & Agarwal, S. (2020). Face mask detection using transfer learning of inceptionv3. In *Big Data Analytics: 8th International Conference, BDA 2020, Sonapat, India, December 15–18, 2020, Proceedings 8* (pp. 81-90). Springer International Publishing.
- Jocher, G.; Stoken, A.; Borovec, J.; Changyu, L.; Hogan, A.; Diaconu, L.; Ingham, F.; Poznanski, J.; Fang, J. & Yu, L. (2020). Bug Fixes and Performance Improvements. <https://doi.org/10.5281/zenodo.4154370>. (Erişim tarihi: 20.04 2023)
- Jones, L., Golan, D., Hanna, S. & Ramachandran, M. (2018). Artificial intelligence, machine learning and the evolution of healthcare: a bright future or cause for concern. *Bone & Joint Res.* 7, 223–225.

- Johnston, A.M. & Edwards, D.S. (1996). Welfare implications of identification of cattle by ear tags. *Veterinary Record*, 138(25), 612-614.
- Kakıcı, A. (2008). Biyometrik Tanıma Sistemleri; <https://ahmetkakici.github.io/genel/biyometrik-tanima-sistemleri/>. (Erişim Tarihi: 26.08.2022)
- Kaya, Y., Arısoy, R.Z., Taner, A., Aksoyak, Ş., Partigöç, F. & Gültekin, İ. (2010). Geleneksel ve doğrudan ekim yöntemlerinin nohut buğday ekim nöbetinde Orta Anadolu kuru koşullarında karşılaştırılması. *Tarım Makinaları Bilimi Dergisi*, 6(4):267-272.
- Khan, R.H., Kang, K.W., Lim, S.J., Youn, S.D., Kwon, O.J., Lee, S.H. & Kwon, K.R. (2020). Animal face classification using dual deep convolutional neural network. *J. Korea Multimedia Soc.* 23 (4) 525–538.
- Kirmikil, M., Ertaş, B. (2020). Tarım 4.0 ile Sürdürülebilir Bir Gelecek. *Icontech International Journal*, 4(1), 1-12.
- Kul, E., Filik, G., Şahin, A., Çayıroğlu, H., Uğurlutepe, E. & Erdem, H. (2018). Effects of some environmental factors on birth weight of Anatolian buffalo calves. *Turkish Journal of Agriculture-Food Science and Technology*, 6(4), 444-446.
- Kul, E. (2020). Determination of the best lactation curve model and lactation curve parameters using different nonlinear models for Anatolian Buffaloes. *Pakistan J. Zool.*, 52: 1291-1297.
- Kul, E., Şahin, A., & Abacı, S.H. (2022). The Effects of Some Environmental Factors on Colostrum Quality in Anatolian Buffaloes. *Anadolu Tarım Bilimleri Dergisi*, 37(3), 655-662.
- Kumar, S. & Singh, S.K. (2014). Biometric recognition for pet animal. *Journal of Software Engineering and Applications*. 7, 470-482.
- Kumar, S., Tiwari, S. & Singh, S. K. (2015). Face recognition for cattle. In 2015 Third International Conference on Image Information Processing (ICIIP) (65-72). IEEE.
- Kumar, S., Pandey, A., Satwik, K.S.R., Kumar, S., Singh, S.K., Singh, A.K. & Mohan, A. (2018). Deep learning framework for recognition of cattle using muzzle point image pattern. *Measurement*, 116, 1-17.

- Kumar, K., Wagan, A.A., Khuhro, M.A., Umrani, A., Chhajro, A., Hafeez, A., & Laghari, A.A. (2020). Texture based FACE recognition using GLCM and LBP schemes. *Indian Journal of Science and Technology*, 13(13), 1401-1411.
- Krishna Chaitanya, G. & Maragatham, G. (2021). Object and obstacle detection for self-driving cars using GoogLeNet and deep learning. In *Artificial Intelligence Techniques for Advanced Computing Applications: Proceedings of ICACT 2020* (pp. 315-322). Springer Singapore.
- Krizhevsky, A., Sutskever, I. & Hinton, G.E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84-90.
- Lantz, B. (2013). *Machine Learning with R*. Birmingham: Packt Publishing Ltd.
- LeCun, Y., Bengio, Y. & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436- 444.
- Li, N., Kusakunniran, W. & Hotta, S. (2020). Detection of Animal Behind Cages Using Convolutional Neural Network. In *2020 17th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON)* (pp. 242-245). IEEE.
- Li, Z., Liu, F., Yang, W., Peng, S. & Zhou, J. (2022). A survey of convolutional neural networks: analysis, applications, and prospects, *IEEE Transactions on Neural Networks and Learning Systems*, 33, 12, 6999-7019.
- Liaghat, S. & Balasundram, S.K. (2010). A review: The role of remote sensing in precision agriculture. *American Journal of Agricultural and Biological Sciences*, 5(1), 50-55.
- Litjens, G., Kooi, T., Bejnordi, B.E., Setio, A.A.A., Ciompi, F., Ghafoorian, M. ...& Sanchez C.I. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60-88.
- Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C.Y. & Berg, A.C. (2016). Ssd: Single shot multibox detector. In *Computer Vision–ECCV 2016: 14th European Conference, Amsterdam, Proceedings, Part I 14* (pp. 21-37). Springer International Publishing.
- Lu, Y., He, X., Wen, Y., Wang, & P.S. (2014). A new cow identification system based on iris analysis and recognition. *International Journal of Biometrics*, 6(1), 18-32.

- Lu, S., Wang, B., Wang, H., Chen, L., Linjian, M., & Zhang, X. (2019). A real-time object detection algorithm for video. *Computers & Electrical Engineering*, 77, 398-408.
- Madiwalar, S.C. & Wyawahare, M.V. (2017). Plant disease identification: A comparative study, In 2017 International Conference on Data Management, Analytics and Innovation (ICDMAI)..
- Mahajan, S., Das, A. & Sardana, H.K. (2015). Image acquisition techniques for assessment of legume quality. *Trends in Food Science & Technology*, 42(2), 116-133.
- Manjunath, B.S. & Ma, W.Y. (1996). Texture features for browsing and retrieval of image data. *IEEE Transactions on pattern analysis and machine intelligence*, 18(8), 837-842.
- Marchant, J. (2002). Secure animal identification and source verification. *JM Communications*, UK, 1-28.
- Mastromichalakis, S. (2020). ALReLU: A different approach on Leaky ReLU activation function to improve neural networks performance. *arXiv preprint arXiv:2012.07564*.
- McLennan, K. & Mahmoud, M. (2019). Development of an automated pain facial expression detection system for sheep (*Ovis Aries*). *Animals*, 9(4), 196.
- Memmedova, N. (2012). Süt Sığırlarında Mastitisin Bazı Yapay Zekâ Yöntemleri Kullanılarak Erken Dönemde Tespiti. Doktora Tezi, Selçuk Üniversitesi. Fen Bilimleri Enstitüsü, Konya.
- Metre, V. & Ghorpade, J. (2013). An overview of the research on texture based plant leaf classification. *arXiv preprint arXiv:1306.4345*.
- Mikołajczyk, A. & Grochowski, M. (2018). Data augmentation for improving deep learning in image classification problem. *International Interdisciplinary PhD Workshop (IIPhDW 2018)*. IEEE, New Jersey. pp. 117-122
- Mori, T., Kuno, Y., Yamakita, O. & Tsukada, M. (2000). U.S. Patent No. 6,081,607. Washington, DC: U.S. Patent and Trademark Office.
- Mukid, M.A. Widiharhi, T., Rusgiyono, A. & Prahutama, A. (2018). Credit scoring analysis using weighted k nearest neighbor. *Journal of Physics*, 1025(1), 012114.

- Nanni, L., Ghidoni, S. & Brahnam, S. (2017). Handcrafted vs. non-handcrafted features for computer vision classification. *Pattern Recognition*, 71, 158-172.
- Neethirajan, S. & Kemp, B. (2021). Digital livestock farming. *Sensing and Bio-Sensing Research*, 32, 100408.
- Nisha, S.S. & Meeral, M.N. (2021). Applications of Deep Learning in Biomedical Engineering. In *Handbook of Deep Learning in Biomedical Engineering* (245-270). Academic Press.
- Nikoo, M.K. & Mahmoud, N.A.S. (2011). Thermodynamic analysis of carbon dioxide reforming of methane in view of solid carbon formation, *Fuel Processing Technology*, 92(3), 678-691.
- Ojala, T., Pietikäinen, M. & Harwood, D. (1996). A comparative study of texture measures with classification based on featured distributions. *Pattern Recognition*, 29(1), 51-59.
- Olivas, E.S., Guerrero, J.D.M., Martinez-Sober, M., Magdalena-Benedito, J.R. & Serrano, L. (Eds.). (2009). *Handbook of research on machine learning applications and trends: Algorithms, methods, and techniques: Algorithms, methods, and techniques*. IGI global.
- Oysun, G. (1987). Ultrafiltrasyon yöntemi ile peynir suyundan elde edilen konsantre proteinin besinlerin zenginleştirilmesinde kullanılması. *Gıda*.12(6).
- Pantic, I., Dimitrijevic, D., Nesic, D. & Petrovic, D. (2016). Gray level co-occurrence matrix algorithm as pattern recognition biosensor for oxidopamine-induced changes in lymphocyte chromatin architecture, *Journal of Theoretical Biology*, 406, 124-128.
- Patrício, D.I. & Rieder, R. (2018). Computer vision and artificial intelligence in precision agriculture for grain crops: A systematic review. *Computers and Electronics in Agriculture*, 153, 69-81.
- Paszke, A., Gross, S., Massa, F., Lerer, A., Bradbury, J., Chanan, G., ... & Chintala, S. (2019). Pytorch: An imperative style, high-performance deep learning library. *Advances in Neural Information Processing Systems*, 32.

- Redmon, J., Divvala, S., Girshick, R. & Farhadi, A. (2016). You only look once: Unified, real-time object detection. In Proceedings of the IEEE conference on computer vision and pattern recognition (779-788).
- Şahin T. (2022). Dizel Makinanın Makina Öğrenmesi Yöntemi Kullanılarak Modellenmesi ve Karar-Destek Mekanizması Oluşturulması. Doktora Tezi, İstanbul Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, İstanbul.
- Sahiner, B., Pezeshk, A., Hadjiiski, L.M., Wang, X., Drukker, K., Cha, K.H. & Giger, M.L. (2019). Deep learning in medical imaging and radiation therapy. Medical physics, 46(1), 1-36.
- Satılmış, A.S. (2022). Amasya İli Manda Yetiştiriciliğinin Durumu, Sorunları ve Çözüm Önerileri. Yüksek Lisans Tezi, Kırşehir Ahi Evran Üniversitesi, Fen Bilimleri Enstitüsü, Kırşehir, 52s
- Selvarajah, S. & Kodituwakku, S.R. (2011). Analysis and comparison of texture features for content based image retrieval. International Journal of Latest Trends in Computing, 2(1), 108-113.
- Selvi, E. (2019). Kentsel Atıksu Arıtma Tesisi Biyolojik Oksijen İhtiyacının (Boi5) Makina Öğrenmesi Yöntemleri ile Tahmin Edilmesi, Yüksek Lisans Tezi. Sakarya Üniversitesi Fen Bilimleri Enstitüsü, Sakarya.
- Shinde, S., Kothari, A. & Gupta, V. (2018). YOLO based human action recognition and localization. Procedia Computer Science, 133, 831-838.
- Shoaib, M. & Sayed, N. (2022). YOLO Object Detector and Inception-V3 Convolutional Neural Network for Improved Brain Tumor Segmentation. Traitement Du Signal, 39(1).
- Shorten, C. & Khoshgoftaar, T.M. (2019). A survey on image data augmentation for deep learning. Journal of Big Data, 6(1), 1-48.
- Skaggs, R. & Crawford, T. (2007). Livestock Identification in New Mexico: Current Status and Implications for National Animal Identification. Agricultural Experiment Station, College of Agriculture and Home Economics, New Mexico State University.

- Soh, L.K. & Tsatsoulis, C. (1999). Texture analysis of SAR sea ice imagery using gray level co-occurrence matrices, *IEEE Transactions on Geoscience and Remote Sensing*, 37(2), 780-795.
- Soysal, M.İ. (2006). Manda ve ürünleri üretimi. Tekirdağ Üniversitesi Ziraat Fakültesi Zootečni Bölümü, Ders Notları. Tekirdağ.
- Soysal, M.İ. (2013). Anatolian water buffalo husbandry in Turkey. *Buffalo Bulletin*, 32 (Special Issiu 1) 293-309.
- Stahl, H., Schädler, K. & Hartung, E. (2008). Capturing 2D and 3D biometric data of farm animals under real-life conditions. In *Proceedings in international conference of agricultural engineering*, SPC03 C (Vol. 1034).
- Stockman, G. & Shapiro, L.G. (2001). *Computer vision*. Upper Saddle River, NJ, USA: Prentice Hall.
- Suthaharan, S. (2016). Support vector machine. In *Machine Learning Models and Algorithms for Big Data Classification: Thinking with Examples for Effective Learning*; Springer US: Boston, MA, USA, 2016; pp. 207–235.
- Suttapakti, U. & Bunpeng, A. (2019). Potato leaf disease classification based on distinct color and texture feature extraction, In *2019 19th International Symposium on Communications and Information Technologies (ISCIT)*, 82-85 September.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D. & Rabinovich, A. (2015). Going deeper with convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition*. 1-9.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J. & Wojna, Z. (2016). Rethinking the inception architecture for computer vision. In *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2818-2826.
- Şahin, A. & Ulutaş, Z. (2014). Anadolu mandalarının değişik metotlara göre tahmin edilen süt verimleri üzerine bazı çevresel faktörlerin etkilerinin belirlenmesi. *Kafkas Üniversitesi Veteriner Fakültesi Dergisi*, 20(1), 79-85.
- Thepade, S.D., & Dhake, A.R. (2021). Fusion of Thepade SBTC and GLCM features for recognizing gender from facial images. In *2021 International Conference on Communication information and Computing Technology (ICCICT)* (1-7). IEEE.

- Thibault, G. (2009). Indices de forme et de texture: de la 2D vers la 3D: application au classement de noyaux de cellules. Doctoral dissertation, Aix-Marseille 2.
- Tomaszewski, M.A. (1993). Record-keeping systems and control of data flow and information retrieval to manage large high producing herds. *Journal of Dairy Science*, 76(10), 3188-3194.
- Tou, J.Y., Tay, Y.H. & Lau, P.Y. (2009). Recent trends in texture classification: a review, In *Symposium on Progress in Information & Communication Technology*, 3(2), 56-59.
- (URF) Understanding Random Forest (2023). <https://towardsdatascience.com/understanding-random-forest-58381e0602d2> . (Erişim Tarihi 20. 04. 2023).
- Uzun, Y., Bilban, M., & Arıkan, H. (2018). Tarım ve Kırsal Kalkınmada Yapay Zeka Kullanımı. VI. Uluslararası KOP Bölgesel Kalkınma Sempozyumu, 26-27.
- Van Dyk, D.A. & Meng, X.L. (2001). The art of data augmentation. *Journal of Computational and Graphical Statistics*, 10(1), 1-50.
- Van Gerven, M.A.J. & Bohte, S.M. (2017). Artificial neural networks as models of neural information processing. *Frontiers Media SA*.
- Vapnik, V., Golowich, S.E. & Smola, A. (1997). Support vector method for function approximation, regression estimation, and signal processing. *Advances in neural information processing systems*, 281-287.
- Veerashetty, S., Virupakshappa, & Ambika. (2022). Face recognition with illumination, scale and rotation invariance using multiblock LTP-GLCM descriptor and adaptive ANN. *International Journal of System Assurance Engineering and Management*, 1-14.
- Walczak, S. (2019). Artificial Neural Networks. In *Advanced Methodologies and Technologies in Artificial Intelligence, Computer Simulation, and Human-Computer Interaction* (pp. 40-53). IGI Global.
- Wolfert, S., Ge, L., Verdouw, C. & Bogaardt, M.J. (2017). Big data in smart farming—a review. *Agricultural Systems*, 153, 69-80.

- Xian, T. S. & Ngadiran, R. (2021). Plant diseases classification using machine learning, In Journal of Physics: Conference Series. 1962 (1), 012024, July.
- Xu, B., Wang, W., Falzon, G., Kwan, P., Guo, L., Chen, G., ... & Schneider, D. (2020). Automated cattle counting using Mask R-CNN in quadcopter vision system. Computers and Electronics in Agriculture, 171, 105300.
- Xu, R., Lin, H., Lu, K., Cao, L. & Liu, Y. (2021). A forest fire detection system based on ensemble learning. Forests, 12(2), 217.
- Yalçın, H. & Baykan, Ö.K. (2013). Hayvanlarda alternatif ve yeni biyometrik kimliklendirme yöntemleri. TÜBİTAK Bilim ve Teknik Dergisi, 46(549), 68-71.
- Yogeshwari, M. & Thailambal, G. (2021). Automatic feature extraction and detection of plant leaf disease using GLCM features and convolutional neural networks, Materials Today: Proceedings.
- Yılmaz, S. (2013). Afyonkarahisar yöresi manda yetiştiriciliği: Küçükçobanlı Köyü örneği (Master's thesis, Adnan Menderes Üniversitesi, Fen Bilimleri Enstitüsü). Aydın.
- Zabir, M., Fazira, N., Ibrahim, Z., & Sabri, N. (2018). Evaluation of pre-trained convolutional neural network models for object recognition. International Journal of Engineering and Technology, 7(3.15), 95-98.
- Zhang, Y., Guo, Z., Wu, J., Tian, Y., Tang, H. & Guo, X. (2022). Real-time vehicle detection based on improved YOLOv5. Sustainability, 14(19), 12274.
- Zhu, D., Pan, R., Gao, W. & Zhang, J. (2015). Yarn-dyed fabric defect detection based on autocorrelation function and GLCM. Autex Research Journal, 15(3),



**T.C.
YOZGAT BOZOK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**