



Burdur Mehmet Akif Ersoy Üniversitesi
Fen Bilimleri Enstitüsü / Bilgisayar Mühendisliği Anabilim Dalı

YÜKSEK LİSANS TEZİ

Sığır Hastalıklarının Görüntü İşleme Yöntemleri ile Tespit Edilmesi

Ali Tezcan SARIZEYBEK

Danışman
Prof. Dr. Ali Hakan IŞIK

**T.C.
BURDUR MEHMET AKİF ERSOY ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
YÜKSEK LİSANS TEZİ**

**SIĞIR HASTALIKLARININ GÖRÜNTÜ İŞLEME
YÖNTEMLERİ İLE TESPİT EDİLMESİ**

Ali Tezcan SARIZEYBEK

Danışman: Prof. Dr. Ali Hakan IŞIK

BURDUR, 2023

ETİK KURALLARA UYGUNLUK BEYANI

Burdur Mehmet Akif Ersoy Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Eğitim Öğretim ve Sınav Yönetmeliğinin ilgili hükümleri uyarınca **Yüksek Lisans** Tezi olarak sunduğum “**Sığır Hastalıklarının Görüntü İşleme Yöntemleri ile Tespit Edilmesi**” başlıklı bu tezin;

- Kendi çalışmam olduğunu,
- Sunduğum tüm sonuç, doküman, bilgi ve belgeleri bizzat ve bu tez çalışması kapsamında elde ettiğimi,
- Bu tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara atıf yaptığımı ve bunları kaynaklar listesinde usulüne uygun olarak verdiğimi,
- Kullandığım verilerde değişiklik yapmadığımı,
- Tez çalışması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını,
- Bu tezin herhangi bir bölümünü bu üniversite veya diğer bir üniversitede başka bir tez çalışması içinde sunmadığımı,
- Bu tezin planlanmasından yazımına kadar bütün safhalarda bilimsel etik kurallarına uygun olarak davrandığımı,

bildirir, aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul edeceğimi beyan ederim.

17/07/2023

(İmza)
Ali Tezcan SARIZEYBEK

ÖNSÖZ

“Sığır Hastalıklarının Görüntü İşleme Yöntemleri ile Tespit Edilmesi” başlıklı bu araştırma için beni yönlendiren, karşılaştığım zorlukları bilgi ve tecrübesi ile aşmamda yardımcı olan değerli Danışman Hocam Prof. Dr. Ali Hakan IŞIK’a teşekkürlerimi sunarım.

Araştırmalarım sırasında yardımlarını gördüğüm değerli can dostum ve çalışma arkadaşım Ömer Can ESKİCİOĞLU’na teşekkür ederim.

Veri kümesini hazırlarken hastalıklar konusunda bilgi ve veri kümesindeki hastalıkların doğruluğunun teyidini aldığım değerli arkadaşım Veteriner Hekim Aykut NACAK’a teşekkür ederim.

0831-YL-22 No`lu Proje ile tezimi maddi olarak destekleyen Burdur Mehmet Akif Ersoy Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğüne teşekkür ederim.

Eğitim hayatımın her aşamasında beni her anlamda destekleyen aileme sonsuz sevgi ve saygılarımı sunarım.

Temmuz, 2023

Ali Tezcan SARIZEYBEK

İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	i
İÇİNDEKİLER	ii
ŞEKİLLER DİZİNİ.....	iii
ÇİZELGELER DİZİNİ	v
SİMGELER VE KISALTMALAR DİZİNİ	vi
ÖZET.....	vii
ABSTRACT.....	viii
1. GİRİŞ.....	1
2. GENEL BİLGİLER.....	3
2.1. Kaynak Özetleri	3
2.2. Sığır Hastalıkları	8
2.2.1. Bovine Papillomatosis Virüs.....	8
2.2.2. İnfeksiyöz Bovine Keratokonjunktivitis	9
2.2.3. Nodüler Ekzantemi.....	10
2.2.4. Şap Hastalığı	11
2.3. Yapay Zekâ	13
2.3.1. Makine Öğrenmesi	13
2.3.2. Yapay Sinir Ağları	14
2.3.3. Tekrarlı Sinir Ağları.....	15
2.3.4. Evrişimsel Sinir Ağları.....	16
3. MATERYAL VE YÖNTEM	19
3.1. Materyal	19
3.1.1. Veri Kümesi	19
3.1.2. Performans Metrikleri	19
3.2. Yöntem.....	22
3.2.1. Histogram Eşitleme.....	22
3.2.2. Veri Çoğaltma	23
3.2.3. SMOTE	25
3.2.4. Makine Öğrenmesi Yöntemleri.....	26
3.2.5. Transfer Öğrenme Yöntemleri	33
3.2.6. Mobil Uygulama ve Web Servis	38
4. ARAŞTIRMA BULGULARI VE TARTIŞMA.....	40
4.1. Performans Sonuçları.....	40
4.2. Tartışma	44
5. SONUÇ VE ÖNERİLER	45
KAYNAKLAR	47
EKLER.....	57
EK 1 - Şekil 3.19. Mobil uygulama ve web servis uygulama şeması	57
EK 2 - Şekil 3.20. Bu çalışmada uygulanan materyal ve yöntemlerin şeması	
..... Hata! Yer işareti tanımlanmamış.	

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 2.1. BPV'nin sığırlar üzerindeki etkileri.....	9
Şekil 2.2. İBK'nin sığırlar üzerindeki etkileri	10
Şekil 2.3. Nodüler Ekzantemi'nin sığırlar üzerindeki etkileri	11
Şekil 2.4. Şap Hastalığının sığırlar üzerindeki etkileri	13
Şekil 2.5. Yapay sinir ağları yapısı	15
Şekil 2.6. LSTM mimarisi	16
Şekil 2.7. ESA mimarisi	16
Şekil 2.8. Evrişim katmanı.....	17
Şekil 2.9. Havuzlama katmanı	17
Şekil 2.10. Tam bağlantılı katman	18
Şekil 3.1. Karmaşıklık matrisi	20
Şekil 3.2. Histogram eşitlemeden önce ve sonra görüntü ve histogram durumları	23
Şekil 3.3. Veri kümesinde ön işleme aşamasında kullanılan yöntemlerin uygulanması	24
Şekil 3.4. SMOTE ile yeni veri oluşturma işleminin gösterimi.....	26
Şekil 3.5. Özellik çıkarımı sonucu özellik haritası	27
Şekil 3.6. Gradyan Artırma algoritması.....	28
Şekil 3.7. AdaBoost algoritması	29
Şekil 3.8. XGBoost algoritması	30
Şekil 3.9. Doğrusal DVS'de en iyi hiper düzlemin bulunması.....	31
Şekil 3.10. Doğrusal olmayan DVS'de en iyi hiper düzlemin bulunması	32
Şekil 3.11. VGG-16 ağ şeması.....	34
Şekil 3.12. VGG-19 ağ şeması.....	34
Şekil 3.13. NasNet mimarisi	35
Şekil 3.14. MobileNetV3-Small mimarisi	36
Şekil 3.15. Inception-V2 mimarisi.....	37
Şekil 3.16. EfficientNet-V2 mimarisi	37
Şekil 3.17. DenseNet mimarisi	38
Şekil 3.18. Mobil uygulama ve web servis akış diyagramı	39
Şekil 4.1. MobileNetV3 çıkarım testi	41
Şekil 4.2. Makine öğrenmesi modellerinin karmaşıklık matrisi sıcaklık haritası.....	42
Şekil 4.3. Transfer öğrenme modellerinin zamana bağlı performans sonuçları	43

Şekil 4.4. Mobil uygulama ekran görüntüleri	43
EK 1 - Şekil 3.19. Mobil uygulama ve web servis uygulama şeması	57
EK 2 - Şekil 3.20. Bu çalışmada uygulanan materyal ve yöntemlerin şeması.....	57



ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 3.1. Veri çoğaltma işleminde kullanılan yöntemler.....	24
Çizelge 3.2. Veri çoğaltma öncesi ve sonrası görüntü sayıları.....	25
Çizelge 4.1. Performans sonuçları	40



SİMGELER VE KISALTMALAR DİZİNİ

AUC	: Area Under the ROC Curve
BPV	: Bovine Papillomatosis Virüs
CNN	: Convolutional Neural Networks
DSA	: Derin Sinir Ağları
ESA	: Evrişimsel Sinir Ağları
GN	: Gerçek Negatif
GP	: Gerçek Pozitif
HE	: Histogram Eşitleme
HGB	: Histogram Gradyan Artırma (HGB)
IoU	: Intersection over Union
İBK	: İnfeksiyöz Bovine Keratokonjunktivitis
KDF	: Kümülatif Dağılım Fonksiyonu
LSDV	: Lumpy Skin Disease Virüs
LSTM	: Long-Short Term Memory
NE	: Nodüler Ekzantemi
RNN	: Recurrent Neural Networks
SE	: Squeeze and Excite
YN	: Yanlış Negatif
YP	: Yanlış Pozitif
YSA	: Yapay Sinir Ağları
YZ	: Yapay Zekâ

ÖZET

Yüksek Lisans Tezi

Sığır Hastalıklarının Görüntü İşleme Yöntemleri ile Tespit Edilmesi

Ali Tezcan Sarızeybek

Burdur Mehmet Akif Ersoy Üniversitesi

Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Ali Hakan IŞIK

Temmuz, 2023

Günümüzde, veteriner alanındaki araştırmalarda görüntü işleme yöntemlerine duyulan ihtiyaç her geçen gün artmaktadır. Bu ihtiyaç, özellikle sığır hastalıklarının erken teşhisinde görüntü işleme yöntemlerine duyulan gereksinimle daha da önem kazanmaktadır. Hayvan sahibinin sığırın hastalanması durumunda veteriner hekime danışması özellikle ulaşım açısından zaman alabilmekte, hastalık, veteriner hekim tarafından teşhis yapılana kadar ilerleyebilmektedir. Bu nedenle görüntü işleme yöntemleri ile özellikle sığır türlerinin hastalıklarının erken teşhisinde öneri getirecek yazılım geliştirilmesi gerekmektedir. Bu tez çalışmasında, çeşitli sığır hastalıklarının yapay zekâ yöntemlerinden biri olan görüntü sınıflandırma yardımıyla tespit edilmesi gerçekleştirilmiştir. Bu çalışmada, Yapay zekâ modeli oluşturmada önce görüntüler toplanıp, hastalıklar analiz edilip, veri üzerinde sınıflandırılması yapılmış ve veri kümesi oluşturulmuştur. Model performansının artması ve veri kümesindeki dengesizliğin giderilmesi için veri kümesindeki görüntüler ve işaretlenen görüntü verileri üzerinde histogram eşitleme, veri artırma ve SMOTE yöntemleri ile ön işleme işlemleri gerçekleştirilmiştir. Veri kümesi hazırlandıktan sonra sınıflandırma modeli eğitimi gerçekleştirilmiş ve performans analizleri yapılmıştır. Performans analizleri sonucunda, probleme en uygun modelin %99.94 doğruluk, %99.94 hassasiyet, %99.94 duyarlılık ve %99.99 AUC skoru ve 0.007 kayıp ile en yüksek performans veren MobileNet-V3 ile eğitilen model olduğuna karar verilmiş ve elde edilen ağırlık dosyası, hazırlanan web servise entegre edilmiştir. Daha sonra, Flutter ile mobil uygulama hazırlanmış ve hastalık tespitinin web servis üzerinden gerçekleştirilip mobil uygulamaya iletilmesi sağlanmıştır. Bu çalışmada hazırlanan mobil uygulama, sığır hastalıklarının ön teşhisinin yapılması kapsamında güncel yapay zekâ yöntemlerinin eğitilmesinden sonra elde edilen yüksek sınıflandırma performansı ile etkin kullanımını göstererek veteriner hekimlere ve sığır yetiştiricilerine yeni bir bakış açısı ve hastalık teşhisinde kolaylıklar sunmaktadır.

Anahtar Kelimeler: sığır hastalık tespiti, görüntü işleme, görüntü sınıflandırma, sığır hastalığı ön teşhisi

Hazırlanan bu Yüksek Lisans tezi Burdur Mehmet Akif Ersoy Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğü tarafından 0831-YL-22 proje numarası ile desteklenmiştir.

ABSTRACT

M. Sc. Thesis

Detection of Cattle Diseases With Image Processing Methods

Ali Tezcan Sarızeybek

**Burdur Mehmet Akif Ersoy University
Graduate School of Natural and Applied Sciences
Department of Computer Engineering**

Supervisor: Prof. Dr. Ali Hakan IŞIK

July, 2023

Today, the need for image processing methods in veterinary research is increasing day by day. This need becomes even more important with the need for image processing methods, especially in the early diagnosis of cattle diseases. It may take time for the owner of the animal to consult a veterinarian, especially in terms of transportation, in case the cattle get sick, and the disease may progress until the diagnosis is made by the veterinarian. For this reason, it is necessary to develop software that will provide suggestions for the early diagnosis of diseases of cattle species, especially with image processing methods. In this thesis, the detection of various cattle diseases with the help of image classification, which is one of the artificial intelligence methods, was carried out. In this study, before creating the artificial intelligence model, images were collected, diseases were analyzed, classified on the data and a data set was created. In order to increase the model performance and eliminate the imbalance in the dataset, preprocessing processes were performed on the images in the dataset and the marked image data with histogram equalization, data augmentation and SMOTE methods. After the dataset was prepared, classification model training was carried out and performance analyzes were made. As a result of the performance analysis, it was decided that the most suitable model for the problem was the model trained with MobileNet-V3, which gave the highest performance with 99.94% accuracy, 99.94% sensitivity, 99.94% sensitivity and 99.99% AUC score and 0.007 loss, and the resulting weight file was sent to the prepared web service. has been integrated. Later, a mobile application was prepared with Flutter, and disease detection was carried out via the web service and transmitted to the mobile application. The mobile application prepared in this study offers veterinarians and cattle breeders a new perspective and convenience in disease diagnosis by showing the effective use with high classification performance obtained after training current artificial intelligence methods within the scope of preliminary diagnosis of cattle diseases.

Keywords: cattle disease detection, image processing, image classification, bovine disease prediagnosis

The present M.Sc Thesis was supported by Burdur Mehmet Akif Ersoy University Scientific Research Projects Coordinatorship Under the Project number of 0831-YL-22.

1. GİRİŞ

Günümüzde veteriner alanındaki araştırmalarda görüntü işleme yöntemlerine duyulan ihtiyaç her geçen gün artmaktadır. Yaralanma tespiti, hastalık tespiti, gebelik teşhisi, ilaç tedavisi gibi veteriner alanındaki araştırmalarda görüntü işleme yöntemlerinin kullanılması bir ihtiyaçtır. Ülkemizde yaygın olarak yetiştirilen sığırların hastalıklarının tespiti, hayvancılık endüstrisi için son derece önemlidir. Bu hastalıklar hem hayvanların hem de insanların sağlığını olumsuz etkileyebilir. Ayrıca, bu hastalıkların yayılması ekonomik kayıplara da neden olabilir. Bu nedenle, sığır hastalıklarının tespiti ve kontrolü, sığır yetiştiricileri, veteriner hekimler ve hayvan sağlığı uzmanları için son derece önemlidir. Sığırların normal bir şekilde hastalıklarının tespit edilebilmesi için hayvan sahibinin bir uzmana danışması özellikle ulaşım açısından zaman alabilmekte, sığırın hastalığı uzman tarafından teşhis yapılana kadar ilerleyebilmektedir. Belirli bir yerde az sayıda veteriner hekim olması ve sığır sayısının fazla olması veterinerin her hastalıklı sığır ile ilgilenememesine neden olmaktadır. Hayvan sağlık uzmanının sığırın bulunduğu konuma ulaşımının hem zaman hem yol açısından maliyetli olması, hastalığın zaman ilerledikçe daha da ilerleme kat etmesi, hastalıklı sığırların fazla olması durumunda uzmanın her bir sığıra yetişememesi gibi problemler gözlemlenmektedir. Bu problemlerin çözümü için görüntü işleme yöntemleri ile oluşturulan bir yapay zekâ modeli ile hastalık sınıflandırmasının yapılması, teşhisin yapılması açısından zaman kazandırabilir. Bu nedenle görüntü işleme yöntemleri ile sığır türlerinin hastalıklarının erken teşhisinin sağlanması önem arz etmektedir.

Sığır hastalıklarının tespiti için birçok yöntem kullanılabilir. Bunlar arasında fiziksel muayene, kan testleri, enfeksiyon belirteçleri ve görüntüleme teknolojileri gibi yöntemler bulunur. Son yıllarda yapay zekâ, sığır hastalık ve problemlerinin tespiti için her geçen gün daha yaygın bir şekilde kullanılmaktadır (Bao ve Xie, 2022). Yapay zekâ ile sığır görüntüleri kullanılarak hastalık teşhisi yapılabilir (Jingqiu vd., 2017). Sığırların yürüyüşleri, hareketleri ve vücut sıcaklıkları gibi parametreler, hastalık teşhisi yapmak için kullanılabilir (Zhao vd., 2018; Fuentes vd., 2020). Bunun yanında görüntü işleme modelinin eksik, hatalı veya yanlış bilgilerle eğitilmesi sonucunda hastalıkların yanlış teşhis edilmesi gibi problemler de ortaya çıkabilir; bu yüzden görüntü işleme modelinde veri kümesi hazırlanırken bir uzmana danışmak, modelin doğruluğu için çok önemlidir. Bu tür bir modelin uygulamaya geçirilmesi bir kişisel bilgisayar üzerinde olursa hayvancılığın daha yoğun görüldüğü yer kırsal kesimler olduğu için bu uygulamaya

eriřim az olabileceğinden dolayı, taşınabilir olması ve daha çok insanda bulunması ile bu uygulamanın hayata geçirileceğı en iyi platform akıllı cep telefonlarıdır. Temel olarak ortak amaç, hastalıkların yapay zekâ ile tespit edilmesi ile insanlara kolaylıkların sağlanmasıdır.

Bu çalışmada 9 adet makine öğrenmesi, 9 adet ESA yöntemi kullanılarak model eğitimi gerçekleştirilmiştir. Bu çalışmada sığır hastalıklarının erken tespit edilmesi ve mobil uygulama ile kullanıcıların uygulamaya kolay erişiminin sağlanması, bu sayede hastalıkların ön teşhisinin gerçekleştirilmesi amaçlanmıştır.



2. GENEL BİLGİLER

2.1. Kaynak Özetleri

Schaefer ve arkadaşları (2004) tarafından yapılan çalışmada, kızılötesi termografinin erken tanı için yetkinliğinin araştırılması amaçlanmıştır. Vücut ağırlıkları ortalama 172 kilogram olan 15 adet seronegatif buzağı kullanılarak bir viral enfeksiyon modeli benimsenmiş, bu buzağılardan on tanesi tip 2 viral diyare virüsü ile aşılanmış, diğerleri ise enfekte edilmemiştir. Kızılötesi karakteristiklerin anlık olarak karşılaştırılması yapılmış, bunun yanında kan, tükürük kortizolü, immunoglobulin A, kan haptogloblin ve klinik sonuçlar ölçülmüştür. Kızılötesi ile buzağların yüzlerinin ölçümleri sonucunda 1 hafta içinde buzağların sıcaklıkları 1,5 ile 4°C arasında artış görülmüştür. Sonuca göre kızılötesi kamera ile hastalıkların erken teşhisinin yapılabildiği elde edilmiştir. Bu çalışma görüntü işleme yöntemleri ile gerçekleştirilebilir, sığırlar üzerinde sıcaklık taraması yapılarak hastalıkların erken teşhiste bulunmasında yardımcı olabilir.

Rachna ve Swamy (2013) tarafından yapılan çalışmada, görüntü işleme teknikleri ile tüberküloz bakterisinin tespit edilmesi amaçlanmıştır. ZN-Stain örnek görüntüleri ön işleme aşamasından geçirilmiş, sonrasında gri görüntüleri azaltmak için görüntüler üzerinde eşikleme yapılmış ve arka plan kaldırılmış, görüntüde sadece bakteri görüntüsü bırakılmıştır. Sınıflandırma algoritması olarak K-Means ve Otsu Eşikleme kullanılmıştır. Sınıflandırma gerçekleştirildikten sonra elde edilen deney sonuçlarına göre K-Means yönteminin doğruluk oranı %98,91, hassasiyeti %99,22, özgüllük oranı %98,73 olarak elde edilmiş, Otsu Eşikleme yönteminin doğruluk oranı %98,36, hassasiyeti %99,02, özgüllük oranı ise %98,02 olarak elde edilmiştir. İki yöntemin performansları birbirine yakındır fakat K-Means yönteminin bu çalışma için en uygun algoritma olduğu gözlemlenmiştir.

Putzu, Caocci ve Ruberto (2014) tarafından yapılan çalışmada, mikroskop görüntülerinden beyaz kan hücreleri incelenerek hücre tanınması ve sınıflandırma yapılması amaçlanmıştır. Önce çekirdeği algılamak yerine önerilen yöntemde ilk yapılan işlem, lökosit izole edip çekirdek ve sitoplazmayı ayırmaktır. Veri kümesinde görüntüler, ALL-IDB adında görüntü veri kümesinden alınmış, veri kümesi 108 adet 300-500 arasında yakınlaştırma oranlarına sahip mikroskop görüntüsü içermektedir. Sınıflandırma için SVM-L, SVM-Q, SVM-P, SVM-R, KNN, NB-G, NB-K ve Karar Ağaçları sınıflandırma modelleri kullanılmıştır. Kromatik özellik setinde yapılan deney sonucunda 4 renkli olanlar arasında doğruluk oranı en yüksek olan modelin %79,3 ile SVM-P ve

NB-K, 7 renkli arasında %87 ile SVM-R, 21 renkli arasında ise %88,4 ile SVM-R olduğu gözlemlenmiştir. Doku özellikleri arasında doğruluk değeri en yüksek olan modelin ise 16 dokuda %77,3 ile NB-G, 80 dokuda ise %90,6 ile SVM-R olduğu gözlemlenmiştir. Farklı özellik kümesinde ise 50 x 245 özellik matrisinde %90,6 ile SVM-R, 131x245 özellik matrisinde ise %93,2 ile SVM-R olduğu gözlemlenmiştir. Yapılan deneye göre bu çalışma için 8 model arasında en uygun sınıflandırma modeli SVM-R olduğu belirtilmiştir.

Cortivo ve arkadaşları (2016) tarafından yapılan çalışmada, termografik görüntülerle dış parazitlerin tespit edilmesi amaçlanmıştır. İlgili çalışmada 20 Holstein ineği, 10 Devon ineği ve 10 Braford boğası kullanılmış, görüntü işleme ile dış parazitlerin sayımının yapılması amaçlanmıştır. Sığırın yan tarafındaki keneler için görsel ve termografik görüntüler arasında 0,32 ve arka ucunda ise 0,84'lük bir korelasyon ile kenelerin tespiti yapılmıştır. Kara sinekler için de 0,82 korelasyon kullanılmıştır. Dış parazitlerin sayımı için termografik görüntülerin kullanılmasının yararlı olduğu gözlemlenmiştir. Yapılan literatür taramasına göre hastalık ve dış etkenlerin tespiti için standart bir kamera yerine sıklıkla kızılötesi kameralar kullanılmıştır. Hayvancılıkla uğraşan insanların kızılötesi kamera kullanmak yerine neredeyse herkesin sahip olduğu akıllı telefon kameraları ile hastalıkların tespitinin yapılması amaçlanmıştır.

Kumar ve arkadaşları (2016) tarafından yapılan çalışmada, sıklıkla görülen bazı cilt hastalıklarının görüntü işleme ve makine öğrenmesi yöntemleri ile tespiti amaçlanmıştır. Eğitim için MS Ramaiyah Sağlık Koleji ve Bangalore&Mysore Sağlık Kolejinden alınan görüntüler kullanılmıştır. Özellik seçimi için alınan görüntüler ön işlemeye sokulmuş, görüntüler siyah beyaz, keskinleştirme, medyan filtresi, yumuşatma, ikili maskeleme, RGB alma, histogram ve sobel operatörü kullanılarak ön işleme aşamasından geçirilmiştir. Sonrasında özellik çıkarımı gerçekleştirilmiş, RGB görüntü HSV görüntüye çevrilmiştir. Tahmin için KNN, Karar Ağaçları ve YSA modelleri kullanılmıştır. Veri kümesinin %67'si eğitim, %33'ü ise test için kullanılmıştır. Deney sonucunda doğruluk oranı %95 olarak elde edilmiştir.

Toğaçar, Ergen ve Sertkaya (2018) tarafından yapılan çalışmada, insan hayatını tehlikeye atan zatürre hastalığının ESA ile akciğer röntgen görüntülerinden tespit edilmesi amaçlanmıştır. Veri kümesinde normal ve pnömoni adında iki kategoriye ayrılmış, bir ile beş yaş arasındaki çocukların göğüs röntgen görüntüleri kullanılmıştır. 1.583 adet normal, 4.266 adet de pnömoni sınıfına ait görüntü olmak üzere toplam 5.849 adet görüntü bulunmaktadır. Veri kümesi üzerinde AlexNet kullanılarak özellik çıkarımı,

TBA kullanılarak özellik indirgenmesi gerçekleştirilmiştir. Karar Ağaçları, Doğrusal Ayrımcılık Analizi, Lineer Regresyon, DVM, En Yakın Komşu ve Softmax yöntemleri kullanılarak sınıflandırma gerçekleştirilmiştir. TBA kullanılmadan gerçekleştirilen performans testlerinde elde edilen sonuçlarda doğruluk oranı en yüksek olan sınıflandırıcının %95,83 ile DVM olduğu gözlemlenmiştir. TBA kullanıldığında ise doğruluk değeri en yüksek olan sınıflandırıcının yine %95,40 ile DVM olduğu gözlemlenmiştir. İkinci durumda, yani TBA kullanılarak yapılan deney sonucunda DVM sınıflandırıcısının duyarlılık oranı %95,68, özgünlük %95,10, hassasiyet %95,07 ve F1 skoru %95,37 olarak elde edilmiştir.

Uzun (2020) tarafından yapılan çalışmada, göz yapısında bulunan lezyonların 13 adet farklı tür teşhisinin yapılması amaçlanmıştır. Retina görüntüleri STARE, DIARETDB0 ve DIARETDB1 veri tabanlarından elde edilmiştir. Görüntüler Cifar-10 ağı ile eğitilmiştir. Görüntülerin %70'i eğitim, %30'u test için ayrılmıştır. STARE veri kümesindeki 400 görüntüden lezyon içeren 358 adet görüntü alınmış, görüntü içindeki farklı hastalıklar tespit edilmiş ve 13 adet hastalık gözlemlenmiştir. DIARETDB0 veri kümesinde ise 20 adet normal, 110 adet DR belirtileri olan görüntü elde edilmiştir. DIARETDB1 veri kümesinde 84 adeti DR mikro anevrizmalarını içeren, 5 adetinin ise DR belirtisi içermeyen görüntüler olmak üzere toplam 89 adet görüntü vardır. Üç veri kümesinde yapılan testler sonucunda başarımları STARE için %91, DIARETDB0 için %98,53, DIARETDB1 için ise %93,01 olarak elde edilmiştir.

Diker (2020) tarafından yapılan çalışmada, kan parazitinin sebep olduğu sıtma hastalığının ve parazit bulaşan kırmızı kan hücrelerinin tespit edilmesi amaçlanmıştır. Sınıflandırma için AlexNet, GoogleNet, SqueezeNet ve ShuffleNet modelleri kullanılmıştır. Veri kümesi olarak Ulusal Sağlık Enstitüleri tarafından sağlanan veri tabanından elde edilmiş eşit parazit ve enfekte olmamış hücre görüntüleri bulunmaktadır. Veri kümesi toplam 27.558 adet hücre görüntüsü içermektedir. Görüntüler %80 eğitim, %20 test için ayrılmıştır. Yapılan deney sonuçlarında doğruluk değeri en yüksek olan model %96,44 ile ShuffleNet'tir. Duyarlılık değeri en yüksek olan model ise %50 ile GoogleNet'tir. Özgüllük açısından en yüksek model ise %50,89 ile AlexNet'tir.

Bütüner ve Calp (2020) tarafından yapılan çalışmada, 2019 yılında başlayan ve tüm dünyaya yayılan, insanların evlerde kapanmasına yol açan ölümcül bir virüs olan Covid-19 virüsünün akciğer tomografi görüntülerinden tespit edilmesi, KNN, ESA ve DSA kullanılarak virüsün tespit edilmesi amaçlanmıştır. Veri kümesi olarak 14.446 adet sağlıklı ve virüsün enfekte olduğu akciğer görüntüleri içeren veri kümesi kullanılmıştır.

Deney sonucunda CNN doğruluk oranının %98,40, DNN oranının %90,37, KNN oranının ise %91,72 olduğu, en düşük hata oranının %98,40 ile CNN olduğu gözlemlenmiştir.

Dandıl ve Serin (2020) tarafından yapılan çalışmada, meme kanserinin tespiti, iyi huylu ve kötü huylu olarak ayırt edilmesi için DenseNet201, Inception-V3, ResNet50 ve Xception ön eğitilmiş ağırları kullanılarak derin sinir ağı modeli oluşturulmuş, 7.909 adet histopatolojik görüntü kullanılarak bir veri kümesi oluşturulmuştur. Modellerin performanslarını artırmak için bırakma ve veri artırma yöntemleri kullanılmıştır. Görüntüler içinde 100 kat, 200 kat ve 400 kat yaklaştırma performans sonuçlarına göre sırasıyla %94,97, %98,01 ve %95,35 doğruluk ile Xception modelinin en iyi sonuç veren model olduğu, ikinci olarak ise sırasıyla %94,49, %97,77 ve %95,08 doğruluk ile DenseNet201 modelinin en iyi sonuç verdiği gözlemlenmiştir. 40 kat yakınlaştırma görüntülerine göre ise en iyi sonuç veren modelin %97,50 doğruluk ile DenseNet201 olduğu gözlemlenmiştir.

Erdem ve Aydın (2021) tarafından yapılan çalışmada, göğüs histopatolojik görüntülerinden göğüs kanserinin tespiti amaçlanmıştır. Sınıflandırma olarak VGG16, Inception-V3 ve iki ağı birleşimi olan VHHist kullanılarak yapılmıştır. Veri kümesi olarak Patolojik Anatomi ve Sitopatoloji tarafından oluşturulan BreakHis veri tabanındaki 82 hastadan oluşan 9.109 mikroskopik tümör görüntülerinden oluşan bir veri kümesi kullanılmıştır. Veri kümesinde 2.480 iyi huylu, 5.429 adet kötü huylu tümör görüntüsü bulunmaktadır. Veri kümesindeki görüntüler ön işleme sokulmuş, görüntü boyutları 244x224 olacak şekilde yeniden boyutlandırılmıştır, performans artışı sağlamak için veri artırma işlemi uygulanmıştır. Deney sonucunda VGG-16, Inception-V3 ve VHHist doğruluk oranları sırayla %92,2, %98,3, %99,03 olarak elde edilmiştir. Sonuçlar, benzer çalışmalardan daha yüksek doğruluk değerine sahiptir.

Uçar (2021) tarafından yapılan çalışmada, göz içi basıncın yükselmesi yüzünden optik sinire zarar veren hastalık olan Glokom hastalığının görüntü işleme ve ESA ile tespiti amaçlanmıştır. Sınıflandırma için VGG-16, Inception-V3, EfficientNet, DenseNet, ResNet50 ve MobileNet modelleri kullanılmıştır. Veri kümesi olarak Li ve arkadaşları tarafından oluşturulan, Beijing Tongren Hastanesinden elde edilen 2.392 glokom, 3.432 normal olmak üzere 5.824 fundus görüntüsü içeren bir veri kümesi kullanılmıştır, deneyde ise 1.711 glokom ve 3.143 normal olmak üzere 4.854 fundus görüntüsü içeren halka açık ve birinci bölümü kullanılmıştır. Deney sonucunda doğruluk, duyarlılık, özgüllük ve kesinlik olarak sırasıyla %96,19, %96,06, %96,06 ve %95,64 sonuç alınan

DenseNet bu çalışma için en uygun model olmuştur. Eğitim süresi en kısa olan model ise 1.692 saniye ile MobileNet olmuştur.

Karaman ve Çınar (2021) tarafından yapılan çalışmada, böbreklerde oluşan taşların Abdominal Bilgisayarlı Tomografi (BT) görüntülerinde sınırlarının ve sayılarının görüntü işleme ile belirlenmesi amaçlanmıştır ve 20 hastaya ait abdominal BT görüntüsü içeren bir veri kümesi kullanılmıştır, böbrekte bulunan taşlara morfolojik aşındırma ve genişletme işlemleri uygulanmış, taşlar ayrılmış ve sayılmıştır. Bazı hastaların solda, sağda, iki böbreğinde taş bulunduğu, bazı hastaların iki böbreğinde de taş bulunduğu gözlemlenmiştir. Yöntemlerin uygulanması sonucunda doğruluk oranının %97, hassasiyet oranının %96 ve özgüllük oranının %100 olduğu gözlemlenmiştir. Morfolojik aşındırma ve genişletme işlemleri uygulanmadan aynı yöntemle doğruluk oranının %93, hassasiyet oranının %95 ve özgüllük oranının %88 olduğu gözlemlenmiştir. İlgili sonuçlara göre morfolojik işlemler sayesinde performansın arttığı gözlemlenmiştir.

Rony ve arkadaşları (2021) tarafından yapılan çalışmada, sığır dış hastalıklarının sınıflandırılmasının gerçekleştirilmesi amaçlanmıştır. Veri kümesi hazırlanırken görüntüler hayvan hastaneleri, sığır çiftlikleri ve internet gibi yerlerden elde edilmiş ve veri kümesi bir veteriner hekim tarafından teyit edilmiştir. Veri kümesinde şap hastalığında 250, nodüler ekzantemi hastalığında 200, infeksiyöz bovine keratokonjunktivitis hastalığında ise 150 adet görüntü bulunduğu belirtilmiştir. Veri kümesindeki görüntüler veri artırımı yapılarak 4.800 eğitim ve 1.200 test olmak üzere toplam 6.000 adet görüntüye çıkarılmıştır. Veri artırımı yapılırken ters çevirme, parlaklık iyileştirme, kaydırma gibi yöntemler uygulanmıştır. Sınıflandırma yapılması için özellik çıkarımı ve sınıflandırma katmanlarından oluşan CNN mimarisi oluşturulmuştur. Bunun yanında VGG-16 mimarisi ve Inception-V3 önceden eğitilmiş model kullanılarak performanslarının karşılaştırması yapılmıştır. Gerçekleştirilen eğitim sonucunda doğruluk, hassasiyet ve F1-Skor değerlerinin, CNN mimarisinde sırayla %92, %90, %91, Inception-V3 modelinde sırayla %95, %93, %92 ve VGG-16 mimarisinde ise sırayla %91, %87 ve %86 olduğu gözlemlenmiştir. Bu çalışmada ilgili çalışmanın veri kümesinden görüntüler izin alınarak kullanılmıştır.

Literatürdeki çalışmalar ve araştırmalar incelendiğinde sığır hastalıklarının görüntü işleme yöntemleri ile tespit edilmesi ile benzer örnek çalışmalar bulunmaktadır. Bu çalışmada, diğer çalışmalardan farklı olarak toplam 18 adet yöntem kullanılarak model eğitimi gerçekleştirilmiş ve performans karşılaştırmaları gerçekleştirilmiştir.

2.2. Sığır Hastalıkları

2.2.1. Bovine Papillomatosis Virüs

Papilloma virüsler yüksek tür zarsız virüslerdir. Bovine papilloma virüsler (BPV) 8 kbp dolaylarında çift zincirli sirküler Deoksiribo Nükleik Asit (DNA) genomlarına sahiptir (Lancaster ve Olson, 1982). Sığır papillomatozisi, sığırların derilerinde çoklu siğil gelişimiyle karakterize iyi huylu bir tümördür (Atasever vd., 2005; Beytut, 2017). BPV ile enfekte olan sığırlar genelde 2 yaşından küçük olanlardır. Hastalık 1 yıl içerisinde gerileme gösterse de bazen kötü huylu tümör özelliği kazanarak karsinomaya dönüşebilir (Nicholls ve Stanley, 2000; Jelinek ve Tachezy, 2005). Papilloma virüslerin sebep olduğu siğiller daha çok dil, saçlı deri, vulva, penis, göğüs, ağız boşluğu ve üst sindirim sisteminde görülür (Munday, 2014). Sığırlar virüsün ana kaynağı ve doğal taşıyıcılarıdır. Virüsler genellikle deride oluşan yaralardan ve diğer defektlerden vücuda enfekte olmaktadır (Campo vd., 1994). Bu hastalığın oluşumunda direkt temas önemli bir bulaş yolu olmakla beraber, tetavür ve kulak küpesi takma işlemleri, ip ve yuların kontamine olan hayvandan dezenfekte işlemi olmaksızın diğerlerine de kullanılması, sağımların makinalarının yetersiz temizliği, kastrasyon, beslenme bozukluğu, hormonal dengesizlik ve mutasyon gibi faktörler önemli rol oynamaktadır (Or vd., 2002; Otter ve Leonard, 2003). BPV sığırlarda gelişimde yavaşlama, canlı ağırlık artışında azalma, süt veriminde azalma, kilo kaybına nadir de olsa ölümle sonuçlanan durumlar yüzünden ekonomik kayıplara neden olur (Carvalho vd., 2013).



Şekil 2.1. BPV'nin sığırlar üzerindeki etkileri (Gallina vd., 2020)

Şekil 2.1'de görüldüğü üzere BPV bulaşan sığır üzerinde kabarcık halinde dokular belirmiştir. Virüs sığırdaki verimin azalmasına sebep olmakta, bu yüzden tespit edilmesi bir sığır yetiştiricileri için gereklidir.

2.2.2. İnfeksiyöz Bovine Keratokonjunktivitis

İnfeksiyöz Bovine Keratokonjunktivitis (IBK), ülseratif keratitis ile karakterize, sığırlarda bir veya her iki gözde de görülebilen etkeni *Moraxella Bovis* olan bir hastalıktır (Quinn vd., 2002). Bulaştığı hayvanlarda nadiren ölümler görünse de genç hayvanlarda büyümenin yavaşlaması, süt ve döl veriminde azalma ve birçok hayvanda kalıcı körlüğe neden olmaktadır (George, 1990; Işık, 2002). İnfeksiyon bağışıklık sistemi zayıf ve duyarlı hayvanlar arasında direkt temas yolla veya vektörlerle kısa sürede sürü içinde yayılmaktadır (Oury vd., 2002). Yüz sineği olarak adlandırılan *Musca Autumnalis*'in kanat ve bacaklarında 3-4 gün canlı kalabildiği tespit edilmiştir (Oury vd., 2002). Yayılmasında ve yoğunluğunda ılıman iklim kuşağında yer alan meralarda yaz ayları, diğer aylara göre hastalığın yayıldığı zaman dilimi olarak saptanmıştır (Quinn vd., 2002;

Snowder vd., 2005). Hastalık belirtilerini başlarda yangı, gözlerde sulanma ve akıntı olarak görülmektedir. İlerideki aşamalarda ise konjunktivitisden korneal ülserasyona doğru giderek kötüleşen süreçte opasite, ödem, perforasyon ve fototopi bulunmaktadır (George, 1990; Moore, 2002). Ülserasyon, ilk tespit edildiği andan itibaren 4-7 gün içinde kornea merkezine doğru limbal sınırdan vaskülarizasyon ile kuşatılacak şekilde gelişebilir (Oury vd., 2002; Holzhauer vd., 2004). İlerleyen durumlarda enfeksiyon tedavi edilmediğinde, gözde körlük meydana gelebilir (Oury vd., 2002). Şekil 2.2’de İBK’nin sığırlar üzerinde oluşturduğu etkiler verilmiştir.



Şekil 2.2. İBK’nin sığırlar üzerindeki etkileri (Firdaus vd., 2013)

2.2.3. Nodüler Ekzantemi

Nodüler Ekzantemi (Lumpy Skin Disease; LSD) hastalığı, Poxviridae ailesinin Capripoxvirus cinsi içinde yer alan Nodüler Ekzantemi Virüsü (Lumpy Skin Disease Virus; LSDV) tarafından oluşturulmaktadır. LSD, Afrika kökenli bir hastalık olmasına rağmen, Ortadoğu’da ve Türkiye’de görülmüştür. Bu enfeksiyon sığır yetiştiriciliği sektöründe ciddi ekonomik kayıplara yol açabilmektedir (Özgünlük, 2015). Sadece

sığırları etkileyen bir hastalık olan LSDV salgınları sırasında, yakın temas halinde olsalar bile koyun ve keçilerde herhangi bir hastalık belirtisi tespit edilememiştir. Güney Afrika'da, 40 milyon koyun bulunmasına rağmen, LSDV salgınlarında koyunlarda herhangi bir vaka bildirimi yapılmamıştır (Coetzer ve Tuppurainen, 2004; MacLachman vd., 2011). Enfeksiyonun bulaşması, mekanik vektör olan artropodlar aracılığıyla gerçekleşir. Çeşitli sokucu ve kan emici sinek türlerinde virüs tespit edilmiştir. Sokucu ve kan emici sineklerin faaliyetleri, sıcaklık ve nemin uygun olduğu aylarda artmaktadır, bu dönemde yeni vakalar ortaya çıkmaktadır (MacLachman vd., 2011). LSDV enfeksiyonunun en önemli semptomu deride oluşan 2-5 cm çapında bütün vücutta yaygın olarak görülen tipik ağrılı nodüllerdir. Nodüller; baş, boyun, meme çevresi, meme, kasık, meme uçları ve ayaklarda sıklıkla dikkati çekmektedir. Ayrıca, karaciğer, işkembe, dalak, akciğer ve sindirim yolunda bu şişkinliklerin aynısı oluşabilmektedir. Göz, burun, ağız, rektum, meme ve genital bölgedeki nodüller kısa sürede ülserleşir ve içerikleri yüksek oranda virüs içermektedirler (Hailu ve Alemayehu, 2015). Derideki nodüller, genellikle 1-2 hafta içinde açılarak ülser benzeri yaralara dönüşür. Bu yaralar zamanla kabuklanır ve kendiliğinden iyileşebilir. Bununla birlikte, mastitis gelişimi süt veriminde azalmaya neden olabilir (Vorster ve Mapham, 2008; Hailu ve Alemayehu, 2015). Şekil 2.3'te Nodüler Ekzantemi'nin sığırlar üzerindeki etkisi verilmiştir.



Şekil 2.3. Nodüler Ekzantemi'nin sığırlar üzerindeki etkileri (Habib vd., 2021)

2.2.4. Şap Hastalığı

Şap hastalığı, sadece çift tırnaklı hayvanları etkilemekle kalmayıp aynı zamanda canlı hayvan ve hayvansal ürünlerin ticaretinde uluslararası kısıtlamalara neden olan ekonomik olarak önemli bir viral hastalıktır. Şap virüsünün etiyolojisi, hastalığın teşhis ve uygun aşıların üretimi açısından önemli bir rol oynamaktadır. Hastalığın endemik

olduğu ülkelerde uygun serotipteki inaktif aşılarla koruyucu aşılama yapılır ve hastalığın yaygınlığının azaltılması için önlemler alınır (İnce ve Kanat, 2015). Şap hastalığı, Picornaviridae ailesinin Aphthovirus alt grubuna aittir. Şap virüsü, 7 farklı serotipe sahiptir: A, O, Asia, C, SAT1, SAT2 ve SAT3. Ayrıca, 67'den fazla alt tipi bulunmaktadır. Şap virüsü, özellikle memeli hayvanlar arasında bulaşıcı bir hastalığa neden olur ve genellikle ayakları, ağız ve burun bölgelerini etkiler. Bu hastalık, özellikle sığırlar, koyunlar, keçiler ve domuzlar gibi tarım hayvanları arasında yaygındır. Şap hastalığı, hayvancılık sektöründe ciddi ekonomik kayıplara yol açabilir ve kontrol altına alınması için sıkı tedbirler gerektirir (King vd., 2000; Tufan, 2006; Çiftçi vd., 2015). Hayvanlar enfeksiyonun klinik aşamasında yüksek virüs varlığı olan salya salgılar. Şap virüsü, solunum yolu ile vücuda girer (Alexandersen vd., 2001). Sığırlarda hastalık, yüksek ateş ve iştahsızlıkla birlikte başlar ve depresyon ve süt veriminde azalma gibi belirtiler görülür. Ateş genellikle iki gün içinde normale döner. Virüs ikinci ve üçüncü günlerde ağız boşluğuna, özellikle dile, meme derisine ve interdigital dokulara yerleşir ve burada 0,5-10 cm çapında veziküllerin oluşmasına neden olur. Bu bölgelerde, virüsün damarlara etkisiyle interstisyel dokuya seröz bir eksudat sızar. Bu eksudat, epitel tabakaya geçer ve stratum spinosum hücrelerinin tonofibrillerini ayırır ve bu hücreler şişer. Bu hücrelerin sitoplazmaları eozinofilik bir görünüm alır ve hücrelerin akantolizis sonucunda mikroskobik veziküller oluşur. Bu veziküller birleşerek gözle görülebilen veziküller haline gelir. Bu aşamada, ağızdan ip şeklinde akan salya oluşur (Fenner vd., 1987; Jubb vd., 2006). Bu veziküller dilin özellikle dorsal ve dorsolateral (üst ve yan) bölgelerinde, yanak ve dudakların iç kısımlarında, sert damakta, diş etlerinde, burun, meme, tırnak bölgesinin korium koronariumunda ve ön mide bölgesinde görülür (Jubb vd., 2006). Şekil 2.4'te Şap Hastalığının sığırlar üzerindeki etkileri verilmiştir.



Şekil 2.4. Şap Hastalığının sığırlar üzerindeki etkileri (CABI, 2022)

2.3. Yapay Zekâ

Yapay zekâ, bilgisayarların ve makinelerin insana benzeyen öğrenme ve düşünme yeteneklerine sahip olması için geliştirilmiş ve hala geliştirilmekte olan bir sistemdir (Oktradiksa vd., 2021). Yapay zekâ temel olarak Makine Öğrenmesi, Yapay Sinir Ağları, Doğal Dil İşleme ve Bilgisayarlı Görü gibi çeşitli kategorilere ayrılmaktadır (Salehi ve Burgueño, 2018). Her bir kategori farklı sorunlara çözüm sunmakla beraber bu yöntemler birlikte kullanılarak da çözümler üretilebilir (Lopez ve Kalita, 2017). Günlük hayatta her geçen gün daha fazla karşımıza çıkan yapay zekâ uygulamaları insan hayatını kolaylaştırmakla beraber işgücünün azaltılmasına yardımcı olmaktadır. Veri analizi ve tahmini, doğal dil işleme, nesne etiketleme, görüntü verisi üzerinden sınıflandırma ve nesne tespiti gibi yöntemler yapay zekâ alanında sıklıkla kullanılmaktadır.

2.3.1. Makine Öğrenmesi

Makine Öğrenmesi, verilere dayalı öğrenme biçimini benimseyen ve klasik yöntemlerin uyum sağlayamadığı problemlere çözüm üretmek için geliştirilmiş bir

bilgisayar bilimleri dalıdır (Bi vd., 2019). Denetimli Öğrenme, Denetimsiz Öğrenme ve Takviyeli Öğrenme olarak 3 ana alt başlığa ayrılmaktadır (Chinnamgari, 2019).


Denetimli Öğrenmede bir veri kümesi vardır ve veriler etiketli bir haldedir, verilen etiketlere göre eğitim gerçekleştirilir ve sonuçlar bu etiketlenmiş verilere göre değerlendirilir. Girdi olarak verinin öznitelikleri verilir ve çıktı olarak veriden çıkarılan sonuç elde edilir. Performans testleri esnasında çıktı olarak verilen verinin etiketi beklenir. Denetimli Öğrenme ile sınıflandırma ve regresyon işlemleri yapılmaktadır (Cunningham vd., 2008).

Denetimsiz Öğrenmede yine bir veri kümesi vardır ancak veriler etiketlenmemiş bir haldedir, bu etiketsiz veriler üzerinde benzerlik ve farklılıklar analiz edilir ve veriler üzerinde bir tahmin yapılır. Yapılan tahmin sonucunda bir ihtimal hesaplanabilir, verilerin öznitelikleri incelenebilir ya da veriler kümelerine ayrılabilir. Denetimsiz Öğrenme ile kümeleme ve veri işleme işlemleri yapılmaktadır (Ghahramani, 2003).

Pekiştirmeli Öğrenmede ise bir veri kümesi kullanılmamaktadır. Belirlenen kurallara dayalı ödül ve ceza sistemi ile yazılım ajanının en yüksek puanı elde edebilmesi için deneme yanılma yöntemi ile en iyi puanın elde edilmesi amaçlanmaktadır. Yazılım Ajanı eylemi gerçekleştirir ve bu eylem ortam tarafından kontrol edilir, eğer eylem kurallar dahilinde ise ödül puanı, kurallar haricinde sonuçlanan bir eylem ise ceza puanı verilir ve eğitim yüksek bir başarıyı elde edildiğine karar verilene kadar tekrar edilir (Kaelbling vd., 1996).

2.3.2. Yapay Sinir Ağları


İnsan beyinde bulunan sinir ağlarının davranışları ile öğrenme yetilerini taklit ederek bir makineye öğrenme kabiliyeti vermek için insan beyninin basitleştirilerek işlevlerinin ve yapısının modellenmesi sonucu Yapay Sinir Ağları (YSA) geliştirilmiştir (Hopfield, 1988). Her bir ağ yapay sinir hücresi olarak adlandırılır ve her bir hücre bir girdi alır. Bu girdiler işlendikten sonra çıktı olarak diğer bir sinir hücresine girdi olarak aktarılır (Yegnanarayana, 2009). YSA, çeşitli katmanlardan oluşur ve bu katmanlar işlevlerine göre ayrı davranışlar sergiler. Her YSA mimarisinde ilk katman giriş katmanıdır ve ağa girdi olarak veriler bu katmana iletilir. Son katman ise çıkış katmanıdır ve işlenen veriler son olarak buraya iletilir ve bu katman üzerinden sonuçlar alınır. Arada kalan katmanlar ise gizli katman olarak adlandırılır (Jain vd., 1996). Katmanlardaki hücreler, bir sonraki katmandaki hücelere bağlıdır. Şekil 2.5'te YSA yapısı bir örnek ile gösterilmiştir.



Şekil 2.5. Yapay sinir ağları yapısı

2.3.3. Tekrarlı Sinir Ağları


Tekrarlı Sinir Ağları (Recurrent Neural Networks; RNN), sıralı veya zaman serisi gibi verileri işlemek için tasarlanmış, YSA'ya dayanan bir makine öğrenmesi yöntemidir (Grossberg, 2013). Eğitimdeki önceki adımlardaki veriyi hafızada tutarak var olan veriyi, sonraki eğitim adımlarında kullanarak sıralı verilerin anlamlarını öğrenmeye çalışır (Medsker ve Jain, 2001). RNN çıktıları daha önceden verilmiş girdi verilerine göre değişir, yani geçmiş verileri hatırlar ve sonraki yapılacak olan tahminlerde bu verilerden faydalanır. RNN, geçmiş bilgilerin önemli olduğu zaman seri analizi, konuşma tanıma, çeviri gibi işlemlerde sıkça kullanılır (Sutskever, 2013). En sık kullanılan yöntem Uzun-Kısa Vadeli Bellek (Long Short-Term Memory; LSTM) yöntemidir. LSTM birimi içinde unutma kapısı, girdi kapısı, hücre ve çıktı kapısı bulunmaktadır. Hücre içinde önceki verilerin unutulup unutulmayacağına unutma kapısı, hücreyi güncellemek ve ağı düzenlemek için girdi kapısı, verileri taşımak için hücre ve tahmin için sonraki birime gönderilecek değeri belirlemek için çıktı kapısı kullanılır (Yu vd., 2019). Şekil 2.6'da LSTM mimarisi gösterilmiştir.



Şekil 2.6. LSTM mimarisi (Fan vd., 2021)

2.3.4. Evrişimsel Sinir Ağları


Evrişimsel Sinir Ağları (ESA), Yapay Sinir Ağlarına dayanan Makine Öğrenmesi yöntemidir ve genel olarak görsellerin analiz edilmesi gibi problemler için kullanılan bir yapıdır (O'Shea ve Nash, 2015). Görüntü işleme alanında nesne algılama, görüntü sınıflandırma gibi yöntemlerde, diğer alanlarda ise doğal dil işleme gibi yöntemlerde kullanılmaktadır (Gu vd., 2018). Girilen veri her bir katmanda işlemlerden geçer ve son katmanda çıktı elde edilir. Girdi, Evrişim, Havuzlama, Bırakma, Aktivasyon Fonksiyonları ve Tam Bağlantılı gibi katmanları vardır (Albawi vd., 2017). Şekil 2.7'de ESA mimarisinin katmanlarının bir örneği gösterilmiştir.



Şekil 2.7. ESA mimarisi


Evrişim katmanı, verilerin özelliklerini algılamak için kullanılır. Görüntü üzerindeki düşük ve yüksek özellikleri algılamak için görüntü üzerinde filtreler uygulanır, filtreler her bir piksel üzerinden geçirilerek özellik haritası çıkarılır. Özellik haritası çıkarıldıktan sonra, adım (stride) yöntemi ile ilk görüntünün filtre etkisinde nasıl etkilendiği denetlenir, harita orijinal görüntüden daha küçük boyutta olacaktır, bu yüzden

etrafına 0 değeri eklenir, bu yöntemle doldurma (padding) denir. Bir modelde evrişim katmanı genellikle birden fazladır (Ajit vd., 2020). Şekil 2.8’de evrişim katmanı gösterilmiştir.




Şekil 2.8. Evrişim katmanı

Havuzlama katmanı, ağdaki uyumsuzluğu kontrol etmek için ağ içindeki parametreler, hesaplama sayısı, görüntülerin kayma boyutunu azaltır. Bu katman için kullanılan en popüler yöntem olan maksimum havuzlama yönteminde uygulanan filtre uygulandığı alandaki en büyük değeri alır (Nagi vd., 2011). Şekil 2.9’da havuzlama katmanı yöntemlerinden biri olan maksimum havuzlama yöntemi gösterilmiştir.



Şekil 2.9. Havuzlama katmanı

Nöronları iki ayrı katmanda birbirine bağlamak için kullanılan tam bağlantılı katman, nöronlarla birlikte ağırlıklardan ve kararlardan oluşur. Genellikle çıktı katmanından hemen önce kullanılır. Önceki katmanlardan gelen görüntü düzleştirilir ve bu katmana aktarılır. Düzleştirilmiş görüntü vektörü, matematiksel işlemlerin gerçekleştirildiği tamamen bağıl katmanlardan geçirilir (Basha vd., 2020). Şekil 2.10'da tam bağlantılı katman gösterilmiştir.



Bırakma katmanı, eğitim setindeki aşırı uyma problemini çözmek için kullanılır. Aşırı uyma, modelin eğitim verilerinin yeni veriler üzerinde test edildiğinde olumsuz bir etkiye sahip olacak kadar uygun olmasıdır. Bu sorunu çözmek için sınır ağından belirli sayıda nöron rastgele olarak çıkarılır. 0,4 değeri verilirse nöronların %40'ı rastgele çıkarılır (Cai vd., 2019).

Aktivasyon fonksiyonları, değişkenler ve ağ arasındaki sürekli ve karmaşık ilişkiyi öğrenmek ve simüle etmek için kullanılırlar. ReLU, Softmax ve Sigmoid gibi fonksiyonlar aktivasyon fonksiyonlarıdır. Ağdaki modelin hangi bilgilerinin bir sonraki düğüme iletilip ileilmeyeceğini belirlerler. Ağa doğrusal olmayan bir yapı kazandırılırlar (Qian vd., 2018).

3. MATERYAL VE YÖNTEM

3.1. Materyal

3.1.1. Veri Kümesi

Veri kümesi, sığırların hastalıkları bazında sınıflara ayrılmış görüntülerden oluşmaktadır. Veri kümesindeki bazı görüntüler Rony vd., (2021) tarafından yapılan çalışmadaki veri kümesinden çalışma sahiplerinden izin alınarak elde edilmiş, diğer görüntüler ise çiftliklerden ve internetten elde edilip birleştirilerek elde edilmiş ve yeni bir veri kümesi hazırlanmıştır. Veri kümesinde bovine papillomatosis virüs, infeksiyöz bovine keratokonjunktivitis, nodüler ekzantemi ve şap hastalığına dair görüntüler bulunmaktadır. Veri kümesindeki görüntüler veteriner hekim tarafından teyit alınarak hazırlanmıştır. Veri kümesinde görüntülerin daha belirgin olması ve eğitimin daha sağlıklı olması için görüntüler üzerinde ön işleme gerçekleştirilmiştir. Görüntülere filtreler eklenerek ve görüntülerin eğimini ve yönünü değiştirerek görüntüler düzenlenmiş, bu sayede görüntüler daha belirgin hale gelmiştir. Ön işleme aşamasında veri kümesinin boyutunu düşürmek ve bu çalışmada kullanılacak modellerin önerilen girdi boyutları 224x224 piksel olduğu için görüntü verileri 224x224 piksel boyutuna yeniden boyutlandırılmış, histogram eşitleme kullanılarak görüntüdeki sığırlar üzerinde bulunan hastalık belirtilerinin daha da belirgin olması sağlanmıştır. Veri kümesi %80 eğitim, %20 doğrulama veri kümesi olmak üzere ikiye ayrılmıştır.

3.1.2. Performans Metrikleri

Yapay zekâ modelleri, performanslarına göre değerlendirilir ve çeşitli performans metrikleri kullanılır. Kullanılan metrikler problemin türüne göre farklılık göstermektedir.

Model eğitimi gerçekleştirildikten sonra test veri kümesindeki veriler üzerinde çıkarım testi yapıldığında her bir veriden çıkan sonucun gerçek sınıfı ve tahmin edilen sınıfı için gerçek pozitif (GP), gerçek negatif (GN), yanlış pozitif (YP) ve yanlış negatif (YN) olmak üzere 4 adet sonuç değeri elde edilmektedir. Elde edilen bu değerler ile karmaşıklık matrisi oluşturulur. Şekil 3.17’de karmaşıklık matrisi verilmiştir.

		Tahmin Edilen Sınıf		Pozitif = 1 Negatif = 0
		1	0	
Asıl Sınıf	1	Gerçek Pozitif	Yanlış Negatif	
	0	Yanlış Pozitif	Gerçek Negatif	

Şekil 3.1. Karmaşıklık matrisi (Santra ve Christy, 2012)

Karmaşıklık matrisinde görüldüğü gibi matriste asıl istenen sınıf pozitif, diğer sınıf ise negatif olarak belirtilmiştir. Matrise göre pozitif veri sınıflandırma modeline verildikten sonra tahmin pozitif ise gerçek pozitif, pozitif veri verildiğinde negatif olarak tahmin edilirse yanlış negatif, negatif sınıf pozitif olarak tahmin edilirse yanlış pozitif, negatif sınıf negatif olarak tahmin edilirse gerçek negatif olarak değerlendirilir (Santra ve Christy, 2012). Test veri kümesindeki tüm veriler tahmin edildikten sonra bu değerler karmaşıklık matrisine eklenir ve buna göre performans metrikleri hesaplanır.

Doğruluk oranı, karmaşıklık matrisindeki doğru sınıflandırılan GP ve GN veri sayılarının tüm verilere olan oranını gösteren bir performans metriğidir. Sınıflandırma performansını değerlendirmek için sıklıkla kullanılır ancak dengesiz veri setlerinde tek başına performans değerlendirmesi için yeterli olmayacağı için diğer performans metrikleri ile kullanılmalıdır. 0 ile 1 arasında bir değer alır ve değer ne kadar yüksekse o kadar iyi sonuç olarak kabul edilir (Hossin ve Sulaiman, 2015). Formül 3.1’de doğruluk hesaplaması fonksiyonu verilmiştir.

$$\text{Doğruluk} = \frac{(GP + GN)}{(GP + GN + YP + YN)} \quad (3.1)$$

Hassasiyet, örüntü tanıma, bilgi edinme, nesne tespiti ve sınıflandırma için kullanılan bir performans metriğidir. Pozitif sınıfın doğru tahmin edilmesi gerçek pozitif ve yanlış pozitif veri sayısının toplamına bölünerek doğru tahmin edilen pozitif sınıf oranı hesaplanır. Yanlış tahmin edilen pozitif veri ne kadar az olursa hassasiyet o kadar artar. Doğruluk metriği gibi veri kümesinin dengesiz olması ihtimali için diğer metrikler ile kullanılmalıdır. 0 ile 1 arasında bir değer alır ve değer ne kadar yüksekse o kadar iyi sonuç olarak kabul edilir (Tharwat, 2020). Formül 3.2’de hassasiyet formülü verilmiştir.

$$Hassasiyet = \frac{(GP)}{(GP + YP)} \quad (3.2)$$

Duyarlılık, örüntü tanıma, bilgi edinme, nesne tespiti ve sınıflandırma için kullanılan bir performans metriğidir. Pozitif sınıfın doğru tahmin edilmesi tüm pozitif sınıf veri sayısına bölünerek doğru tahmin edilen pozitif sınıf oranı hesaplanır. Gerçek pozitif olan verilerin yanlış negatif olarak tahmin edildiği durumların azalması duyarlılık skorunu artırır. Hasta olan bir sığırın sağlıklı olarak tahmin edilmesi, sağlıklı sığırın hastalıklı olarak tahmin edilmesinden daha riskli ve belki ölümcül bir durum olduğu için bu çalışmada duyarlılık ve duyarlılık skorunun yüksek olması hastalığın yanlış tahmin edilmemesi açısından çok önemli bir metriktir. Doğruluk ve hassasiyet metriklerinde verilen sebep duyarlılık için de geçerli olup, diğer metrikler ile değerlendirmelidir. 0 ile 1 arasında bir değer alır ve değer ne kadar yüksekse o kadar iyi sonuç olarak kabul edilir (Grandini vd., 2020). Formül 3.3’te duyarlılık fonksiyonu verilmiştir.

$$Duyarlılık = \frac{(GP)}{(GP + YN)} \quad (3.3)$$

Eğri Altında Kalan Alan (Area Under the ROC Curve; AUC), Alıcı İşletim Karakteristiği (Receiver Operating Characteristic; ROC) eğrisi altında kalan alanı göstermektedir. ROC eğrisi 0 ile 1 arasında olan eşik değerlerinin altında elde edilen gerçek pozitif oranının ve yanlış pozitif oranının eğrisidir. 0 ile 1 arasında bir değer alır ve değer ne kadar yüksekse o kadar iyi sonuç olarak kabul edilir. Değerin 0,5 civarında olması rastgele sınıflandırma yapıldığı, 1 civarında olması durumunda iyi sınıflandırma yapıldığı anlaşılabilir. AUC, dengesiz veri kümesi ile eğitilen modellerde kullanıldığında doğruluk metriğine göre daha güvenilir sonuçlar vermektedir (Wu ve Flach, 2005). Gerçek pozitif oranı duyarlılık ile aynı şekilde hesaplanır, yanlış pozitif oranı ise Formül 3.4’te verildiği gibi hesaplanır.

$$YPO = \frac{(YP)}{(YP + GN)} \quad (3.4)$$

Kayıp, eğitilen modelin veri kümesi üzerindeki tahminlerinin verilerin gerçek sınıflarından ne kadar uzak olduğunu hesaplamak için kullanılan performans metriğidir. Model eğitimi esnasında kayıp değeri hedef fonksiyon olarak kullanılır ve eğitim esnasında nasıl bir performansa sahip olduğu gözlemlenebilir. Kayıp değeri ne kadar düşük değer olursa o kadar iyi model performansının olduğunu göstermektedir. Kayıp hesaplamak için kullanılan çeşitli fonksiyonlar vardır ve problemin türüne ve veri kümesinin yapısına göre bu fonksiyonlar değişmektedir. Sınıflandırma problemleri için ikiden fazla sınıfa sahip olan veri setlerinde kategorik, sınıf sayısı iki olan veri setlerinde ikili kayıp fonksiyonları kullanılmalıdır. Regresyon problemlerinde genellikle ortalama kare hatası veya ortalama mutlak hata kullanılırken sınıflandırma problemleri için genellikle çapraz entropi kullanılır. Bu çalışmada kayıp değerini hesaplamak için hedef fonksiyon ikiden veri kümesinde ikiden fazla sınıf bulunduğu için kategorik çapraz entropi olarak seçilmiştir (Zhang ve Sabuncu, 2018). Bu çalışmada kullanılan kategorik çapraz entropi fonksiyonu Formül 3.5'te verilmiştir.

$$L_{CE} = - \sum_{i=1}^n t_i \log(p_i) \quad (3.5)$$

3.2. Yöntem

3.2.1. Histogram Eşitleme


Bu çalışmada kullanılan ön işleme adımlarından biri olan histogram eşitleme (HE), görüntü verilerinin kontrastını artırmak için kullanılan bir görüntü işleme yöntemidir. Görüntü verisi üzerinde piksel yoğunlukları Kümülatif Dağılım Fonksiyonu (KDF) ile histogramdaki değerler toplanarak dengelenir. Formül 3.6'da kümülatif dağılım fonksiyonu verilmiştir (Krutsch ve Tenario, 2011).

$$CDF = \sum_{j=1}^x h(j) \quad (3.6)$$

Her bir pikselin kümülatif dağılımı hesaplandıktan sonra histogram eşitleme yapılır, Formül 3.7'de histogram eşitleme formülü verilmiştir.

$$he(i) = \left(\frac{cdf(1) - cdf_{min}}{MxN - cdf_{min}} * (L - 1) \right) \quad (3.7)$$

Şekil 3.2’de veri kümesinde bulunan bir görüntü üzerinde histogram eşitleme örneği verilmiştir.



Şekil 3.2. Histogram eşitlemeden önce ve sonra görüntü ve histogram durumları


3.2.2. Veri Çoğaltma

Veri kümesinde 3.010 adet hastalık görüntü verisi bulunmaktadır. Bu veriler eğitim sonrası performansın artması için veri artırımı yöntemi ile veri çoğaltma işlemi yapılmıştır. Veri çoğaltma işleminde kullanılan yöntemler ve etki oranları Çizelge 3.1’de verilmiştir.

Çizelge 3.1. Veri çoğaltma işleminde kullanılan yöntemler

Yöntem	Oran
Kesme	Yatay %15, Dikey %15
Döndürme	Sola ve Sağa 15°
Kırpma	%0 - %40
Doygunluk	%25
Parlaklık	%25 Karartma ve Aydınlatma
Renk Tonu Ayarlama	25°

Veri çoğaltma işlemlerinde kullanılan yöntemlerin veri kümesindeki bir görüntü üzerinde uygulanması Şekil 3.3'te verilmiştir.



Şekil 3.3. Veri kümesinde ön işleme aşamasında kullanılan yöntemlerin uygulanması


Veri kümesindeki görüntüler üzerinde rastgele olarak Çizelge 3.1'de verilen yöntemler uygulanmış ve görüntü sayısı artırılmıştır. Çizelge 3.2'de veri kümesinde veri artırma işlemi uygulanmadan önce ve uygulandıktan sonra elde edilen görüntü sayıları verilmiştir.

Çizelge 3.2. Veri çoğaltma öncesi ve sonrası görüntü sayıları

Hastalık	Veri Çoğaltma Öncesi	Veri Çoğaltma Sonrası
Bovine Papillomatosis Virüs	615	1.847
İnfeksiyöz Bovine Keratokonjunktivitis	823	2.468
Nodüler Ekzantemi	811	2.432
Şap Hastalığı	761	2.282
Toplam	3.010	9.029

3.2.3.SMOTE

Veri kümesinin dağınık olması durumunda model eğitimi sonrası performans değerleri dengesiz olarak elde edilebilir (He ve Garcia, 2009). Bu dengesizliği gidermek için veri kümesindeki her bir sınıfın veri sayısını dengelemek gerekir. Aşağı örnekleme ile diğer sınıf görüntü sayılarının, veri sayısı en az olan sınıfa eşitlenmesi gerçekleştirilebilir ancak bu yöntem veri sayısı az olan veri setlerinde performansı daha da düşürebilir. Yukarı örnekleme ile diğer sınıf veri sayılarının veri sayısı en fazla olan sınıfa eşitlenmesi ile gerçekleştirilir. Veri sayısının az olması durumunda olumsuz bir etki oluşturmamaktadır ancak veri sayısında dengesizliğin çok olması durumunda performansı olumsuz şekilde etkilemektedir. Sentetik Azınlık Aşırı Örnekleme Tekniği (Synthetic Minority Over-sampling Technique; SMOTE), yukarı örnekleme için geliştirilmiş olan bir yöntem olup veri sayısı az sayıda olan sınıflarda var olan veriler üzerinden diğer verilere olan benzerlikleri ve farklılıkları da hesaba katarak rastgele veriler üretmektedir (Chawla vd., 2002). Şekil 3.4'te SMOTE ile sentetik veri üretimi gösterilmiştir.




Şekil 3.4. SMOTE ile yeni veri oluşturma işleminin gösterimi

Şekil 3.4’te görüldüğü gibi rastgele seçilen veri X1’dir, en yakın komşu, yani X1 verisine özellikleri en çok benzeyen veri ise X2’dir. Bu örnekte k değışkeni, yani kıyaslanacak olan komşu sayısı 1 olarak belirlenmiştir. X1 ile X2 arasındaki “diff” olarak belirtilen uzaklık ile 0 ile 1 arası “gap” olarak belirtilen rastgele bir sayı çarpılarak X1 verisine eklenir ve bu sayede r olarak belirtilen sentetik veri oluşturulur (Fernández vd., 2018). Bu çalışmada kullanılan makine öğrenmesi yöntemlerinde görüntü verileri numpy dizilerine çevrildiği için veri kümesi SMOTE yöntemi ile yukarı örnekleme yapılmıştır. Bu çalışmada SMOTE kullanarak veri kümesindeki sınıf bazlı veri sayısının dengesizliğinin engellenmesi amaçlanmıştır.

3.2.4. Makine Öğrenmesi Yöntemleri

Bu çalışmada performans karşılaştırması yapılabilmesi için çeşitli makine öğrenmesi yöntemleri kullanılmıştır. Veri kümesindeki veriler görüntü verileri olduğu için öncelikle veriler numpy dizilerine çevrilmiş, ardından özellik çıkarımında veri kümesinin tümünde en yüksek performans elde edilmiş olan ImageNet ağırlıklı VGG-16 ile görüntü verileri üzerinde özellik çıkarımı yapılmıştır. VGG-16 ile yapılan özellik

ıkarım sonucu veri kumesindeki orijinal grntler ve grntlerin zellik ıkarımı sonucu elde edilen grntler Őekil 3.5'te verilmiřtir.



Őekil 3.5. zellik ıkarımı sonucu zellik haritası

zellik ıkarımından sonra makine ğrenmesi yntemleri ile eğitim gerekleřtirilmiř, doęrulama veri kumesi zerinde gerekleřtirilen testler ile performans metrikleri elde edilmiřtir.

Gradyan Artırma (Gradient Boosting), bir birleřik ğrenme algoritmasıdır ve zayıf ğrencileri dngler ilerledike eksiklerini tamamlayarak gl ğrenciye dnřtrmek iin tasarlanmıřtır. Kayıp fonksiyonu kullanılarak ğrencilerin hataları llr ve hataları en aza indirmek iin yapıya yeni bir ğrenici eklenir. ğrenici, gradyan iniř yntemi ile bu hatalara odaklanarak hata azaltmaya alıřılır. Eğıtimde kayıp daha da azalmazsa eğıtim sonlandırılır. Gradyan Artırma, oęunlukla Karar Aęaları ile kullanılır.

Boosting algoritmaları genellikle eksik verili veya büyük veri kümesi olan problemlerde makine öğrenmesi algoritmaları arasında hızlı bir eğitim süresi ve başarılı sonuçlar vermektedir. Tüm hatalar minimize etmeye çalışılırken aşırı öğrenme sorunu ortaya çıkarabileceği için hiperparametrelerin optimizasyonunun yapılması gerekir (Natekin ve Knoll, 2013). Şekil 3.6’da Gradyan Artırma algoritması verilmiştir.

Girdi: Veri seti $\{(x_i, y_i)\}_{i=1}^n$, Kayıp fonksiyonu $L(y, F(x))$, M döngü sayısı

Algoritma:

1. Sabit bir değer ile modeli başlat

$$F_0(x) = \arg_{\gamma} \min \sum_{i=1}^n L(y_i, \gamma)$$

2. For m = 1’den M’e kadar:

1. Sözde artıkları hesapla

$$r_{im} = -\left[\frac{\partial L(y_i, F(x_i))}{\partial F(x_i)}\right]_{F(x)=F_{m-1}(x)} \quad \text{for } i = 1, \dots, n$$

2. Eğitim seti ile eğitim gerçekleştir

$$\{(x_i, r_{im})\}_{i=1}^n$$

3. Tek Boyutlu Optimizasyon Problemi çözerek γ_m çarpanını hesapla

$$\gamma_m = \arg_{\gamma} \min \sum_{i=1}^n L(y_i, F_{m-1}(x_i) + \gamma h_m(x_i))$$

4. Modeli güncelle

$$F_m(x) = F_{m-1}(x) + \gamma_m h_m(x)$$

3. Çıktı: $F_m(x)$

Şekil 3.6. Gradyan Artırma algoritması (Friedman, 2001)

Karar Ağaçları, doğadaki ağaçlar gibi dal ve yapraklara benzer bir düğüm yapısına sahiptir ve bu dal ve yapraklar üzerinden karar kuralları oluşturularak ve böl ve yönet yöntemini temel alarak ağaç üzerinde yukarıdan aşağı doğru tüm veya çoğu verilerin belirli bir sınıfa sınıflandırılmasına kadar tekrar edilir. Karar Ağaçları karar üzerine dayalı ve parametre almayan bir pekiştirmeli öğrenme yöntemidir. Ağaç ne kadar derin olursa o kadar iyi öğrenme oranı ancak o kadar karışık karar yapısı vardır (Dinov, 2018). Ağaç yapısını görselleştirmek mümkün ve kolay olmakla birlikte Karar Ağaçları veri üzerinde ufak bir değişiklik olması durumunda farklı bir ağaç yapısı oluşabileceğinden stabil olmayan bir yapıya sahiptir (Kingsford ve Salzberg, 2008). Karar Ağaçları çoğunlukla sınıflandırma, karar analizi gibi problemlerde kullanılır.

Adaptif Artırma (Adaptive Boosting; AdaBoost), Gradyan Artırma algoritmasını temel alan ve karar ağaçları üzerine kurulu bir birleşik öğrenme algoritmasıdır. Freund ve Schapire (1995) tarafından formüle edilmiştir. Zayıf öğreniciler öğrenirken hatalı bir

öğrenme davranışı sergilerse bu hatalı öğrencilere öncelik verilerek hatalara odaklanılır ve eğitimde hatalar bu sayede azaltılır. Ardışık sıralanan zayıf öğrenciler birleştirilerek güçlü öğrenci elde edilir. AdaBoost ile dengesiz veri kümesi üzerinde eğitim gerçekleştirildiğinde iyi performans değerleri elde edilir (Schapire, 2013). Şekil 3.7’de AdaBoost yönteminin algoritması verilmiştir.

Girdi: Veri seti $\{(X_i, Y_i)\}_{i=1}^n$, Hata fonksiyonu $E(f(x), y, i) = e^{-y_i f(x_i)}$, Zayıf öğrenciler $h: x \rightarrow \{-1, 1\}$

1. For t in 1 ... T:
 1. $h_t(x)$ seç:
 1. ϵ_t 'yi minimize eden $h_t(x)$ zayıf öğrencisini bul. $\epsilon_t = \sum_{i=1}^n \omega_{i,t}$
 2. $\alpha_t = \frac{1}{2} \ln \left(\frac{1-\epsilon_t}{\epsilon_t} \right)$
 2. Topluluğa ekle $F_t(x) = F_{t-1}(x) + \alpha_t h_t(x)$
 3. Ağırlıkları güncelle
 1. $\omega_{i,t+1} = \omega_{i,t} e^{-y_i \alpha_t h_t(x_i)}$
 2. $\omega_{i,t+1}$ renormalize et

Şekil 3.7. AdaBoost algoritması (Schapire, 2013)

Aşırı Rastgeleleştirilmiş Ağaçlar (Extremely Randomized Trees; ExtraTrees), karar ağaçlarını temel alan bir birleşik öğrenme algoritmasıdır. Ekstra ağaçlar yönteminde rastgele bölme noktaları oluşturularak çok sayıda karar ağacı kümesi oluşturulur. Her bir kümede karar ağaçları algoritmasından farklı olarak en iyi sonuç bağıni bölme noktası olarak seçmek yerine rastgele bir bölme noktası seçilerek daha fazla ihtimal elde edilmesi sağlanır (Geurts vd., 2006). Ekstra Ağaçlar dengesiz ve kirli veri setlerinde iyi performans göstermektedir (Truica ve Leordeanu, 2017). Sınıflandırma ve regresyon için kullanılır.

Gradyan Artırma algoritmasını temel alan Aşırı Gradyan Artırma (Extreme Gradient Boosting; XGBoost), uçtan uca karar ağaçları üzerine kurulu birleşik öğrenme algoritmasıdır. Chen ve Guestrin (2016) tarafından geliştirilmiştir. Gradyan Artırma ve AdaBoost gibi, çok sayıda zayıf öğrenciden bir güçlü öğrenci oluşturularak hata oranını azaltmak hedeflenir. Ağaçların karmaşıklığını kontrol etmek ve aşırı uymayı ortadan kaldırmak için düzenleme yöntemi kullanılır. Sınıflandırma için log-loss veya regresyon için kare hata gibi, farklı problemler için özelleştirilebilir hedef fonksiyonları içerir (Chen vd., 2019). Veri kümesindeki eksik veriler otomatik olarak işlenerek kullanıcının veri kümesinde fazladan işlem yapılmasını önleyerek karmaşıklık engellenir (Ren vd., 2017). Paralel ve dağıtım hesaplama özelliği ile hızlı bir şekilde hesaplama yapılır. Şekil 3.8’de XGBoost algoritması verilmiştir.

Girdi: Veri seti $\{(x_i, y_i)\}_{i=1}^n$, Kayıp fonksiyonu $L(y, F(x))$, M adet zayıf öğrenici, α öğrenme oranı

Algoritma:

1. Sabit bir değer ile modeli başlat

$$\hat{f}_0(x) = \arg_{\theta} \min \sum_{i=1}^N L(y_i, \theta)$$

2. For m = 1'den M'e kadar:

1. Gradyan ve türevini hesapla

$$\hat{g}_m(x_i) = \left[\frac{\partial L(y_i, f(x_i))}{\partial f(x_i)} \right]_{f(x)=f_{(m-1)}(x)}$$

$$\hat{h}_m(x_i) = \left[\frac{\partial^2 L(y_i, f(x_i))}{\partial f(x_i)^2} \right]_{f(x)=f_{(m-1)}(x)}$$

3. Eğitim seti ile eğitim gerçekleştir

$$\{x_i - \frac{\hat{g}_m(x_i)}{\hat{h}_m(x_i)}\}_{i=1}^N$$

$$\hat{\phi}_m = \arg_{\phi \in \Phi} \min \sum_{i=1}^N \frac{1}{2} \hat{h}_m(x_i) \left[-\frac{\hat{g}_m(x_i)}{\hat{h}_m(x_i)} - \phi(x_i) \right]^2$$

$$\hat{f}_m(x) = \hat{f}_{(m-1)}(x) + \hat{f}_m(x)$$

4. Modeli güncelle

$$\hat{f}_m(x) = \hat{f}_{m-1}(x) + \hat{f}_m(x)$$

3. Çıktı: $\hat{f}(x) = \hat{f}_{(M)}(x) = \sum_{m=0}^M \hat{f}_m(x)$


Şekil 3.8. XGBoost algoritması (Chen ve Guestrin, 2016)

Rastgele Orman, Karar Ağaçları yöntemini temel alan bir birleşik öğrenme algoritmasıdır. Veri kümesi üzerinde rastgele örnekler alınır ve her bir örnek için bir karar ağacı oluşturulur. Karar ağaçlarından elde edilen sonuçlar bir araya getirilir ve problem türüne göre sonuçlar değerlendirilir. Sınıflandırma probleminde karar ağaçlarından elde edilen sınıflandırma sonuçlarının çoğunluğu bir sınıfa aitse sonuç olarak o sınıf döndürülür (Daho vd., 2014). Regresyon probleminde ise ağaçlardan çıkan tahminlerin ortalaması alınır (Segal, 2004). Veri kümesinden çeşitli özelliklerin kullanılması ile aşırı uyma önlenir ve veri kümesindeki özelliklerin önem sırası ve etki analizi gibi bilgiler elde edilir (Breiman, 2001).

K-En Yakın Komşu algoritması en yakın komşularının sınıflarına ve verilerine göre sınıflandırma ve regresyon yapmaya yarayan bir algoritmadır. Veri kümesi verildikten sonra algoritmaya verilen “k” parametresine göre verilen veriye Öklid, Manhattan veya Minkowski uzaklık fonksiyonlarına göre en yakın k kadar komşu seçilir ve buna göre sınıflandırma yapılır veya regresyon problemi ise değerleri belirlenir (Peterson, 2009).


Karmaşık modellere uyum sağlayabilir ancak büyük veya düzensiz veri setlerinde yavaş çalışmaktadır (Hassanat, 2018).

Destek Vektör Sınıflandırma (DVS), çok boyutlu veri uzayını sınıflara ayırabilmek için olabilecek hiper düzlem olarak adlandırılan en iyi karar sınırını çizmek için geliştirilmiş bir algoritmadır (Mammone vd., 2009). DVS hiper düzlemi oluşturmak için gerekli olan uç verileri seçilir ve seçilen bu veriler destek vektörü olarak adlandırılır (Noble, 2006). DVS’de sınıflandırma işlemi verinin destek vektörlerine göre hesaplanan hiper düzlemin hangi alanına geldiğine göre gerçekleştirilir. DVS, Doğrusal DVS ve doğrusal olmayan DVS olmak üzere iki türe ayrılır. Doğrusal DVS tek bir doğru ile iki sınıfa ayrılabilen veri setleri için kullanılır. Doğrusal olmayan DVS ise doğrusal bir dağılıma sahip olmayan, verilerin tek bir doğru ile iki sınıfa ayıramayacağı veri türlerinde kullanılır (Boswell, 2002). Şekil 3.9’da doğrusal DVS’de en iyi hiper düzlem bulunması verilmiştir.



Şekil 3.9. Doğrusal DVS’de en iyi hiper düzlemin bulunması (Ghosh vd., 2019)

Şekil 3.9’de görüldüğü gibi veriler tek bir doğrusal çizgi ile ayrılabilir ancak olması gereken en doğru uzaklıkların belirlenmesi için iki farklı sınıftaki bu çizgiye en yakın iki veri bulunur ve bu verilerin birbirlerine olan uzaklıkları ölçülerek en iyi hiper düzlem bulunmaya çalışılır.



Şekil 3.10. Doğrusal olmayan DVS'de en iyi hiper düzlemin bulunması (Gunn, 1998)


Şekil 3.10'da görüldüğü gibi doğrusal olmayan DVS yönteminde veriler tek bir çizgi ile ayrılmamaktadır. Bunun için X ve Y olarak iki boyutu olan uzaya Z boyutu eklenir. Şekil üzerinde ikinci aşamada görüldüğü gibi doğrusal DVS'ye benzer şekilde tek çizgi ile ikiye ayrılabilen bir veri uzayı elde edildikten sonra Z boyutu 1'e eşitlenerek veri uzayı tekrar iki boyutlu hale getirildiğinde doğrusal olmayan DVS problemi için en iyi hiper düzlem elde edildiği görülmektedir.

Histogram Gradyan Artırma (Histogram Gradient Boosting; HGB), Gradyan Artırma algoritmasını temel alan bir birleşik öğrenme algoritmasıdır. Gradyan Artırma algoritmasının algoritma akışı üzerinde işlemler devam ederken veri kümesi eşit histogramlara bölünerek, küme içindeki verilerin özellikleri histogramlar aracılığı ile gruplama yapılarak özellikleri sınıflandırılır (Guryanov, 2019). Verilen veri kümesine göre model oluşturulur ve elde edilen modelde hata değerleri hesaplanır ve verilerden oluşan histogram grupları ile gradyanlar hesaplanır ve sonraki eğitimde hata değerini azaltmak için hatalar ağırlıklara eklenerek tekrar hesaplanır ve belirlenen döngüye kadar devam edilir (Ekanayake, 2023). Verilerin histogramlar ile gruplanması verilerin tutarlı bir şekilde işlenmesine ve eğitimin hızlı gerçekleşmesi sağlanır ancak veri kümesinde veri dağılımının az olduğu kısımlarda eğitim tutarsız gerçekleşebilir.

3.2.5. Transfer Öğrenme Yöntemleri


Bu çalışmada Transfer Öğrenme yöntemi ile literatürde sıkça kullanılan çeşitli ESA yöntemleri kullanılmıştır. Normal bir ESA ağı eğitimi için model özel olarak en baştan oluşturulurken katmanlar bir bilgiye sahip değildir ve ancak eğitim esnasında yeni bilgi edinilir (Day ve Khoshgoftaar, 2017). Transfer Öğrenme ile bir veri kümesi üzerinde önceden eğitilmiş bir model üzerinde bazı katmanların dondurularak bu dondurulan katmanların eğitim esnasında öğrenmesini engelleyerek daha hızlı ve daha tutarlı bir performans elde edilmesi hedeflenir (Naz vd., 2022). Transfer Öğrenme yönteminde daha önceden model üzerinde bir eğitim gerçekleştirildiği için katmanlarda bilgiler tutulmakta ve yeni bir veri, eğitim için ağı gönderildiğinde önceki bilgilerin üzerine eğitim gerçekleşmektedir (Soni, 2018). Özel modellerde veri kümesindeki veri sayısının az olması modelin performansını etkileyebilecekken Transfer Öğrenme yönteminde az veri ile iyi sonuçlar alınabilir. Önceden eğitilmiş bir model üzerine eğitim yapılacağı için eğer ağı üzerindeki katmanlarda verilen verinin aynısı veya benzeri bir veri varsa eğitim süresi daha hızlı gerçekleşmektedir (Tan vd., 2018). Bu çalışmada önceden eğitilmiş çeşitli ESA modelleri kullanılarak model eğitimi gerçekleştirilmiştir.

VGG-16, 13 adet evrişim katmanı, 3 adet tam bağlantılı katman ve 5 adet maksimum havuzlama katmanı içeren bir ESA'dır (Tammina, 2019). VGG-16'da art arda sıralanmış evrişim katmanı ve tam bağlantılı katmanlar kullanılır. Evrişim katmanları ile görüntüde özellik çıkarımı yapılarak görüntünün özelliklerini öğrenilir, havuzlama katmanları ile ise görüntüdeki boyutu azaltarak özellikleri özetlenir ve tam bağlantılı katmanlar ile bu özellik haritasıyla sınıflandırma yapılır. Tüm katmanlar 3x3 piksel boyutunda filtrelerle sahiptir. Model karmaşıklığının diğer ESA mimarilerine göre daha az olmasına rağmen büyük veri setlerinde iyi bir performans gözlemlenmektedir (Quan vd., 2019). Girdi katmanı 224x224 piksel boyutunda görüntü kabul etmektedir. Evrişim katmanlarında Doğrultulmuş Doğrusal Birimler (Rectified Linear Unit; ReLU) aktivasyon fonksiyonu kullanılmaktadır. Havuzlama katmanlarında maksimum havuzlama katmanı kullanılmaktadır. Tam bağlantılı katman ReLU aktivasyon fonksiyonu kullanılmaktadır ve katmanların her birinde 4.096 nöron bulunmaktadır (Iliev ve Trivedi, 2020). Çıktı katmanında Softmax fonksiyonu kullanılmaktadır. Şekil 3.11'de VGG-16 ağı şeması verilmiştir.



Şekil 3.11. VGG-16 ağ şeması

VGG-19, VGG-16'ya benzer bir yapıya sahiptir. VGG-16'da 13 olan evrişim katmanını ve 3 adet tam bağlantılı katman vardır, VGG-19'da 16 evrişim katmanını ve 3 tam bağlantılı katman bulunmaktadır (Cheng ve Zhou, 2020). Şekil 3.12'de VGG-19 ağ şeması verilmiştir.



Şekil 3.12. VGG-19 ağ şeması

RegNetX-160, 160 milyon parametreye sahiptir ve büyük veri setlerinde iyi performans elde edilmesi için geliştirilmiştir. Girdi görüntüsünün boyutu modelin boyutuna bağlı olarak değişmektedir. Modelde farklı görüntü boyutundaki görüntüler ve farklı boyutlardaki veri setleri ile eğitim yapılabilir. Büyük veri setleri ile eğitim sağlandığında yüksek performans sonuçlarına sahip olunabilir ancak küçük boyuttaki veri setlerinde büyük veri kümesindeki gibi iyi performans sergileyemeyebilir (Li vd., 2021). Farklı derinlik, genişlik ve eğim parametreleri ile değiştirilerek kullanılabilir. Genel olarak görüntü sınıflandırma problemleri için kullanılır (Xu vd., 2021).

Nöral Mimari Arama Ağı (Neural Architecture Search Network; NasNet), Nöral Mimari Arama (Neural Architecture Search) kullanılarak otomatik olarak tasarlanmış bir ESA mimarisidir. Google Brain tarafından geliştirilmiştir. NasNet Mobile modeli daha çok MobileNetV3 gibi mobil ve gömülü cihazlarda kullanılmak için tasarlanmış bir modeldir ve bu sayede eğitim ve sınıflandırma zamanı azdır. Genellikle nesne tespiti, segmentasyon ve görüntü sınıflandırma problemlerinde kullanılır (Zoph vd., 2018). Şekil 3.13'te NasNet mimarisi verilmiştir.




Şekil 3.13. NasNet mimarisi (Zoph vd., 2018)

Şekil 3.12'de görülen azaltma hücresinde çeşitli evrişim katmanları, havuzlama katmanları ve aktivasyon fonksiyonları bulunur. Normal hücrede ise ortalama havuzlama ve aktivasyon fonksiyonları bulunur.

MobileNetV3, mobil ve gömülü cihazlarda hızlı ve stabil bir şekilde kullanılması için geliştirilmiş bir ESA mimarisidir. NAS ve NetAdapt algoritması ile birleştirilerek mobil ve gömülü cihazların işlemcilerine uygun hale getirilmiştir. Eğitim sonrası elde edilen model mobil cihazlara uygun üretilmemiş ESA modellerinden daha az boyuta


sahiptir. Mobil ve gömülü cihazlar için üretildiği için diğer ESA modellerine göre daha az parametreye sahip olduğundan dolayı eğitim aşaması ve modelde sınıflandırma süresi az zaman alır (Yao vd., 2021). MobileNetV2'den farklı olarak yeni aktivasyon fonksiyonları, katman yapıları ve ağırlık kalibresi gibi özellikler eklenmiştir (Kavysahree ve Sharkawy, 2021). Genellikle nesne tespiti, segmentasyon ve görüntü sınıflandırma problemlerinde kullanılır. Şekil 3.14'te bu çalışmada kullanılan MobileNetV3-Small mimarisi verilmiştir.



Şekil 3.14. MobileNetV3-Small mimarisi (Howard vd., 2019)

Şekil 3.13'te görülen darboğaz katmanları içinde çeşitli evrişim katmanları içeren, önceki katmandaki verinin boyutunun azaltılması için kullanılan bir yapıdır. 3x3 bir darboğazda 1x1, 3x3 ve 1x1 evrişim katmanları vardır. SE ise Squeeze-And-Excite olarak geçer ve verinin sıkıştırılarak özelliklerin kalibre edilmesi için kullanılır. ReLU ve HS aktivasyon fonksiyonlarıdır.

Inception-V2, Google tarafından Inception serisi için geliştirilmiştir. Özellik çıkarımı için paralel evrişim işlemleri ve farklı boyutlarda filtreleme katmanları içeren Inception blokları kullanılır (Szegedy vd., 2016). Inception-V1'de evrişim katmanlarında uygulanan 5x5 filtre yerine 3x3 filtre kullanılarak hesaplamanın daha hızlı olması sağlanmıştır (Harshaw Kamal vd., 2022). Farklı boyutlardaki veri setleri ile çalışabilmektedir. Paralel evrişim katmanları ile optimize edilmesi sayesinde yüksek performans alınırken aynı zamanda model eğitimi daha hızlı gerçekleşmektedir (Das vd., 2022). Nesne tanıma, görüntü sınıflandırma ve segmentasyon gibi problemlerde kullanılır. Şekil 3.15'te Inception-V2 mimarisi verilmiştir.



Şekil 3.15. Inception-V2 mimarisi (Szegedy vd., 2016)

Inception-V3, Google tarafından Inception serisi için geliştirilmiştir. Inception-V2 mimarisi ile benzer özellikler taşımaktadır ancak Inception-V3 Inception-V2'ye nazaran daha fazla parametre içermektedir. Mimari açıdan Inception-V3'te etiket düzeltme kullanılarak sınıflandırmada aşırı öğrenmenin giderilmesi sağlanmıştır. Bunun yanında 7x7 çarpanlara ayrılmış evrişim katmanları kullanılmış (Szegedy vd., 2015), RMSprop optimizier kullanılmıştır (Stefenon vd., 2022).


Daha düşük boyutta modellerin elde edilmesi ve eğitim süresinin kısaltması için EfficientNet geliştirilerek EfficientNet-V2 geliştirilmiştir. Mimarisinde bileşik ölçekleme adında bir yöntem kullanarak derinlik, genişlik ve çözünürlük faktörleri dengelenmek istenmiştir (Shoeibi vd., 2022). EfficientNet mimarisinde sırasıyla 1x1 Evrişim, Derin Evrişim, SE ve 1x1 Evrişim içeren MB Evrişim katmanı ve sırasıyla 3x3 evrişim, SE ve 1x1 evrişim katmanları içeren kaynaşmış MB evrişim kullanılır (Zheng vd., 2023). Derin evrişim katmanı normal evrişim katmanındaki filtrelerin tüm girdi katmanlarına uygulanması yerine her bir girdi katmanı için ayrı filtreler uygulanmasıdır. Şekil 3.16'da EfficientNetV2 mimarisi verilmiştir.



Şekil 3.16. EfficientNet-V2 mimarisi (Shoeibi vd., 2022)

DenseNet, her katmandaki çıkışın direkt olarak sonraki tüm katmanlara bağlanması sağlanarak tüm katmanların bu katmandan bilgi almasını ve farklı özelliklerin birleştirilebilmesi sağlanır. Bu bağlantılar sayesinde parametreler de paylaşıldığı için bilgi akışı kolaylaşmakta, eğitim daha tutarlı olmakta ve daha az zaman almaktadır (Zhu

ve Newsam, 2017). DenseNet nesne tespiti, segmentasyon ve görüntü sınıflandırma gibi problemlerde kullanılabilir. Şekil 3.17’de DenseNet mimarisi verilmiştir.




Şekil 3.17. DenseNet mimarisi (Huang vd., 2017)

3.2.6. Mobil Uygulama ve Web Servis

Bu çalışmada hastalıklarının tespit edilmesi için kullanıcının kolaylıkla erişim sağlayabileceği ortam olan mobil cihazlar için uygulama geliştirilmiş, bu uygulama üzerinden görüntünün elde edilip hastalık tespitinin yapılması sağlanmıştır. Mobil uygulama, Flutter ile geliştirilmiştir. Flutter, Google tarafından geliştirilen açık kaynaklı ve çapraz platform bir arayüz geliştirme aracıdır. Flutter’da uygulama geliştirmek için aynı şirket tarafından üretilen Dart programlama dili kullanılır (Windmill, 2020). Flutter ile geliştirilen uygulamalar günümüzde Android, iOS, Windows, Linux, MacOS ve Web için derlenebilir (Tyagi, 2021). Bu çalışmada Flutter ile mobil uygulama hazırlanmış ve FLASK ile hazırlanan web servis ile haberleşmesi sağlanmıştır. Eğitilen görüntü işleme modeli sunucuda çalıştırılmış, mobil uygulama tarafından sunucuya gönderilen görüntü modele girdi olarak verildikten sonra çıktı mobil uygulama tarafından alındıktan sonra bu sonucu ve hastalık hakkında bilgileri kullanıcıya gösterebilmektedir. Hazırlanan mobil uygulama hem Android hem de iOS işletim sistemli telefonlar için derlenebilir halde oluşturulmuştur.

Mobil uygulama ve görüntü işleme modelinin iletişiminin sağlanması için oluşturulmuş olan web servis, mobil uygulamadan görüntü ile gelen istekler sunucuya aktarılıp sunucu tarafında görüntü işleme modelinde çıkarım yapıldıktan sonra çıkarım sonuçları web servise gönderilir. Web servis ise isteği yapan istemciye çıkarım sonuçlarının gönderilmesini sağlar. Sunucu tarafında görüntü işleme modeli çalıştırılıp sınıflandırma yapılabilir. Veri kümesi sunucuda tutulmuş ve model eğitimi sunucu tarafında gerçekleştirilmiştir. Mobil cihazdan elde edilen görüntüler sunucuda çalışan web servis aracılığı ile sunucuya gönderildikten sonra görüntülerdeki hastalıkların

belirginleşmesi için bu kısımda HE filtresi uygulanır, yani görüntü modele sokulmadan önce ön işleme yapılır. Ardından görüntü verisini modele girdi olarak ekleyebilmek için görüntü yeniden boyutlandırılır. Görüntü işleme modelinde çıkarım yapılırken diğer kullanıcıların aynı zamanda yaptığı istekler sıraya alınır. Sırası gelen istek görüntünün model üzerinde çıkarımı yapılır ve çıkarım sonuçları web servise aktarılır. Şekil 3.18’de mobil uygulama ve web servisin akış diyagramı verilmiştir. EK 1 - Şekil 3.19’da ise mobil uygulama ve web servisin uygulama şeması verilmiştir. EK 2 - Şekil 3.20’de bu çalışmada uygulanan materyallerin ve yöntemlerin şeması verilmiştir.



Şekil 3.18. Mobil uygulama ve web servis akış diyagramı

4. ARAŞTIRMA BULGULARI VE TARTIŞMA

4.1. Performans Sonuçları


Makine öğrenmesi ve ESA ile transfer öğrenme yöntemleri kullanılarak veri kümesindeki eğitim verileri ile modeller eğitildikten sonra doğruluk, hassasiyet, duyarlılık, eğri altındaki alan ve kayıp değerleri elde edilmiş, veri kümesindeki doğrulama verileri üzerinde yapılan performans sonuçları Çizelge 4.1’de verilmiştir.

Çizelge 4.1. Performans sonuçları

Yöntem	Doğruluk	Hassasiyet	Duyarlılık	AUC	Kayıp
XGBoost	0,94629014	0,94629571	0,94629014	0,96501627	0,02685492
Rastgele Orman	0,94518272	0,94529685	0,94518272	0,94523421	0,02740863
AdaBoost	0,89977851	0,90824354	0,89977851	0,93483841	0,05011074
Ekstra Ağaçlar	0,94407530	0,94420446	0,94407530	0,96364912	0,02796234
Gradyan Artırma	0,94407530	0,94415939	0,94407530	0,96344179	0,02796234
Karar Destek Sınıflandırma	0,94629014	0,94646618	0,94629014	0,96501169	0,02685492
Karar Ağaçları	0,93133997	0,93157383	0,93133997	0,95535410	0,03433001
K-En Yakın Komşu	0,94407530	0,94427090	0,94407530	0,96337018	0,02796234
HGB	0,94629014	0,94638928	0,94629014	0,96504254	0,02685492
VGG-16	0,9839423	0,9855394	0,9811738	0,9990965	0,0750390
VGG-19	0,9822812	0,9833610	0,9817276	0,9991115	0,0668298
RegNetX-160	0,7297896	0,8399654	0,5376522	0,9094973	0,7820617
NasNet Mobile	0,9972314	0,9972299	0,9966777	0,9999437	0,0228231
MobileNetV3	0,9994462	0,9994462	0,9994462	0,9999939	0,0078844
Inception-V2	0,99114066	0,99112588	0,98947954	0,99974954	0,03570770
Inception-V3	0,9983388	0,9983379	0,9977851	0,9999707	0,0103529
EfficientNet-V2	0,9988926	0,9988926	0,9988926	0,9999951	0,0200255
DenseNet	0,9950166	0,9950166	0,9950166	0,9999613	0,0160031

Çizelge 4.1’de görüldüğü gibi derin öğrenme yöntemleri kullanılarak eğitilen modellerde başarımlar çok yüksektir. Doğruluk, hassasiyet ve duyarlılık sonuçlarının her model için yakın olması veri kümesinin dengeli olduğunu göstermektedir. AdaBoost hariç kullanılan makine öğrenmesi yöntemlerinde doğruluk, hassasiyet, duyarlılık ve AUC metriklerinde 0,95’e yakın sonuçlar elde edilmiştir, yine AdaBoost hariç kayıp değerleri 0,02’ye yakın olarak elde edilmiştir. Derin öğrenme yöntemlerinde ise RegNet hariç tüm yöntemler 0,99’a yakın olarak elde edilmiş, kayıp değerleri RegNet hariç 0,1 ile 0 arasında elde edilmiştir. Tüm performans metrikleri kıyaslandığında virgülden sonraki iki rakamın benzer olduğu, bu virgülden sonraki iki rakamdan sonraki sayılar kıyaslandığında ise doğruluk, hassasiyet, duyarlılık, AUC ve kayıp değerlerinin hepsinde daha iyi sonuç veren modelin MobileNetV3 olduğu gözlemlenmiştir.

MobileNetV3 ile doğrulama veri kümesi üzerinde gerçekleştirilen çıkarım testi Şekil 4.1’de verilmiştir. Şekil 4.1’de görüldüğü gibi kırmızı ile işaretlenenler yanlış tahminlenmiş, yeşil ile işaretlenenler ise doğru tahminlenmiştir.




Şekil 4.1. MobileNetV3 çıkarım testi

Makine öğrenmesi ile eğitilmiş olan modellerde, veri kümesindeki doğrulama veri kümesi üzerinde gerçekleştirilmiş olan testlerde elde edilmiş olan doğru pozitif, doğru negatif, yanlış pozitif ve yanlış negatif değerleri ile oluşturulmuş olan karmaşıklık matrisinin sıcaklık haritası Şekil 4.2’de verilmiştir.




Şekil 4.2. Makine öğrenmesi modellerinin karmaşıklık matrisi sıcaklık haritası

Transfer öğrenme ile eğitilmiş olan ESA modelleri üzerinde her bir eğitim adımında eğitim ve doğrulama veri setleri üzerinde gerçekleştirilmiş olan testlerde elde edilen sonuçlar grafik halinde Şekil 4.3'te verilmiştir. Şekil 4.3'te verildiği gibi grafiklerde eğitim ve doğrulama verileri her adımda yakın değerler olarak elde edilmiş, bu zamana bağlı gözlemlenen değerler ve öğrenme eğrileri incelendiğinde veri kümesinin sınıf başına görüntü verisi sayısının dengeli olduğu, gözlem üzerine modelde aşırı uymanın olmadığı gözlemlenmiştir.



Şekil 4.3. Transfer öğrenme modellerinin zamana bağlı performans sonuçları

Kayıp değeri en düşük olan model olan MobileNetV3 modeli web servis ile entegre edilmiştir. Hazırlanan mobil uygulamanın ana ekran, sınıflandırma sayfası ve sınıflandırma sonucu ekran görüntüleri Şekil 4.4'te verilmiştir.



Şekil 4.4. Mobil uygulama ekran görüntüleri

4.2. Tartışma

Bu çalışmada ESA modellerinden elde edilen bulgular beklenen sonuçtan yüksek olmuştur. Bunun sebebi bir mimarinin katmanları oluşturup sıfırdan eğitmek yerine ağırlıkları önceden eğitilmiş model kullanılarak transfer öğrenme yapılması olabilir. Veri kümesinin bazı görüntülerinin de kullanıldığı Rony vd., (2021) tarafından yapılan çalışmada bu çalışmada da kullanılan VGG-16 ve Inception-V3 modelleri kullanılmış ve eğitim sonrası Inception-V3 modelinde %95 doğruluk, %93 hassasiyet, %93 duyarlılık ve %5 kayıp elde edilmiş, VGG-16 modelinde %91 doğruluk, %87 hassasiyet, %89 duyarlılık ve %9 kayıp elde edilmiştir. İlgili çalışmadan elde edilen görüntülere yeni görüntüler eklendiği ve ön işleme aşamalarında farklı işlemler kullanıldığı için daha farklı bir sonuç elde edilmesi gözlemlenmiştir.

Bu çalışmada, güncel makine öğrenmesi ve ESA yöntemlerinin, HE, görüntü verisi çoğaltma ve SMOTE gibi ön işleme yöntemleri ile birleştirilmesi ile yüksek performans değerleri elde edilmiştir. Geliştirilen yöntemler ve mobil uygulama ile sığır hastalıklarının ön teşhisinde yüksek performansı ile güvenilir sonuçlar sunması sağlanmıştır. Veteriner hekim ve sığır yetiştiricilerine hastalıkların ön teşhisinde etkili bir şekilde yardımcı olmasına olanak sunulmaktadır. Görüntü işleme ve yapay zekâ yöntemlerinin veteriner alanında kullanımına ve hastalık teşhisindeki ilerlemelere katkıda bulunmaktadır.

5. SONUÇ VE ÖNERİLER

Bu çalışmada hazır veri kümesinden bazı görüntüler alınarak, çiftlikler ve internet üzerinden elde edilen BPV, İBK, NE ve Şap hastalıklarına dair görüntüler birleştirilmiş ve yeni bir veri kümesi hazırlanmıştır. Bu çalışma için hazırlanan veri kümesi veteriner hekimler tarafından onaylanmıştır. Model eğitilmeden önce Histogram Eşitleme kullanılmış ve veri kümesindeki görüntülerde bulunan hastalıkların daha belirgin olması sağlanmıştır. Görüntü veri çoğaltma yöntemi kullanılmış ve veri kümesinde bulunan 3010 adet görüntü 9.029'a çıkarılmıştır. Son olarak SMOTE kullanılmış ve veri kümesindeki görüntülerin sınıf başına olan görüntülerin sayısı dengelenmiştir. Son olarak veri kümesi %80 eğitim, %20 doğrulama veri kümesi olmak üzere ikiye ayrılmıştır. Ön işleme aşamalarından sonra 9 adet makine öğrenmesi algoritması ve 9 adet ESA algoritması ile model eğitimi gerçekleştirilmiştir. ESA algoritmaları transfer öğrenme ile gerçekleştirilmiştir.

Eğitim sonrası yapılan performans testinde tüm modellerde doğruluk, duyarlılık, hassasiyet ve AUC değerlerinin birbirlerine yakın değerler olduğu gözlemlenmiştir. Makine öğrenmesi ile eğitilen modellerde 0,89-0,94 arası doğruluk değeri elde edilirken ESA ile eğitilen modellerde RegNetX-160 hariç 0,98-0,99 arası doğruluk, duyarlılık, hassasiyet ve AUC değeri elde edilmiştir. Eğitim sonrası gerçekleştirilen performans testinin sonuçları çizelge ile, eğitim esnasında eğitim ve doğrulama veri kümesi üzerinde gerçekleştirilen performans değerleri ise grafiklerle gösterilmiştir. ESA ile eğitilen modellerde bu metriklerin yakın olması sebebi ile kayıp değerleri karşılaştırılarak en iyi modelin 0,0078844 kayıp değeri ile MobileNetV3 olduğu gözlemlenmiştir.

Bu çalışmada Flutter ile çapraz platform bir mobil uygulama ve sunucu üzerinde çalışacak bir web servis hazırlanmış, mobil uygulamadan sığırın görüntüsü alındıktan sonra web servise iletilmesi ve web servisin alınan görüntüyü modele girdi olarak vererek hastalık tespitinin yapılması sağlanmıştır. Hastalık tespiti yapıldıktan sonra web servis sınıflandırma sonucunu mobil uygulamaya göndermekte ve mobil uygulama da kullanıcıya tespit edilen hastalığın detaylı bilgileri ile bilgilendirmesi yapmaktadır.

Bu çalışma ile sığır hastalıklarının ön teşhisinin daha erken ve hızlı yapılması, veteriner hekimin iş yoğunluğunun ve zaman kaybının azaltılması amaçlanmaktadır. İlerleyen çalışmalarda sığır iç ve dış hastalıklarının görüntü işleme yöntemleri ile tespiti yapılabilir, bunun yanında sadece sığır hastalıklarının tespiti yerine diğer çiftlik ve evcil hayvanların hastalık tespiti yapılabilir ve görüntü sınıflandırma yerine görüntünün

zerinde hastalığın hangi konumda olduėunun anlařılması iin nesne tespiti ve segmentasyon ile tespit edilmesi gerekleřtirilebilir.



KAYNAKLAR

- Ajit, A., Acharya, K., ve Samanta, A. (2020). A review of convolutional neural networks. *International Conference on Emerging Trends in Information Technology and Engineering (ic-ETITE)* (pp. 1-5). IEEE.
- Albawi, S., Mohammed, T. A., ve Al-Zawi, S. (2017). Understanding of a convolutional neural network. *International Conference on Engineering and Technology (ICET)* (pp. 1-6). IEEE.
- Alexandersen, S., Oleksiewicz, M. B., ve Donaldson, A. I. (2001). The early pathogenesis of foot-and-mouth disease in pigs infected by contact: a quantitative time-course study using TaqMan RT-PCR. *Journal of General Virology*, 82(4), 747-755.
- Atasever A., Çam Y., ve Atalay Ö. (2005). Bir stıır sürüsünde deri papillomatosis olguları. *Ankara Üniversitesi Veteriner Fakültesi Dergisi*, 52 (3), 197-200.
- Bao, J., ve Xie, Q. (2022). Artificial intelligence in animal farming: A systematic literature review. *Journal of Cleaner Production*, 331, 129956.
- Basha, S. S., Dubey, S. R., Pulabaigari, V., ve Mukherjee, S. (2020). Impact of fully connected layers on performance of convolutional neural networks for image classification. *Neurocomputing*, 378, 112-119.
- Beytut, E. (2017). Pathological and immunohistochemical evaluation of skin and teat papillomas in cattle. *Turkish Journal of Veterinary & Animal Sciences*, 41(2), 204-212.
- Bi, Q., Goodman, K. E., Kaminsky, J., ve Lessler, J. (2019). What is machine learning? A primer for the epidemiologist. *American Journal of Epidemiology*, 188(12), 2222-2239.
- Boswell, D. (2002). Introduction to support vector machines. *Departement of Computer Science and Engineering University of California San Diego*, 11.
- Breiman, L. (2001). Random forests. *Machine learning*, 45, 5-32.
- Bütüner, R., ve Calp, M. H. (2020). *COVID-19 Detection from Lung Tomography Images Using Deep Learning and Machine Learning Methods* (No. 4097). EasyChair.
- CABI (2022). foot-and-mouth disease in ruminants. (2022). *CABI Compendium*.
- Cai, S., Shu, Y., Chen, G., Ooi, B. C., Wang, W., ve Zhang, M. (2019). Effective and efficient dropout for deep convolutional neural networks. *arXiv preprint arXiv:1904.03392*.
- Campo, M. S., Jarrett, W. F. H., O'neil, W., ve Barron, R. J. (1994). Latent papillomavirus infection in cattle. *Research in Veterinary Science*, 56(2), 151-157.
- Carvalho, R. F. D., Sakata, S. T., Giovanni, D. N. S., Mori, E., Brandão, P. E., Richtzenhain, L. J., ve Stocco, R. D. C. (2013). Bovine papillomavirus in Brazil:

- detection of coinfection of unusual types by a PCR-RFLP method. *BioMed research international*, 2013.
- Chawla, N. V., Bowyer, K. W., Hall, L. O., ve Kegelmeyer, W. P. (2002). SMOTE: synthetic minority over-sampling technique. *Journal of artificial intelligence research*, 16, 321-357.
- Chen, T., ve Guestrin, C. (2016). Xgboost: A scalable tree boosting system. In *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining* (pp. 785-794).
- Chen, T., He, T., Benesty, M., ve Khotilovich, V. (2019). Package ‘xgboost’. *R version*, 90, 1-66.
- Cheng, S., ve Zhou, G. (2020). Facial expression recognition method based on improved VGG convolutional neural network. *International Journal of Pattern Recognition and Artificial Intelligence*, 34(07), 2056003.
- Chinnamgari, S. K. (2019). *R Machine Learning Projects: Implement supervised, unsupervised, and reinforcement learning techniques using R 3.5*. Packt Publishing Ltd.
- Coetzer, J. A. W., ve Tuppurainen, E. (2004). Lumpy skin disease. *Infectious diseases of livestock*, 2, 1268-1276.
- Cortivo, P. D., Dias, E., Barcellos, J. O. J., Peripolli, V., Costa Jr, J. B. G., Dallago, B. S. L., ve McManus, C. M. (2016). Use of thermographic images to detect external parasite load in cattle. *Computers and Electronics in Agriculture*, 127, 413-417.
- Cunningham, P., Cord, M., ve Delany, S. J. (2008). Supervised learning. *Machine learning techniques for multimedia: case studies on organization and retrieval*, 21-49.
- Çiftçi, M. K., Ortatatlı, M., Erer, H., Hatipoğlu, F., ve Özdemir, Ö. (2015). Şap Hastalığı. *Veteriner Sistemik Patoloji 1.cilt (Sindirir-Solunum)*, 1. Baskı, Selçuk Üniversitesi Basımevi, Konya, 5-8.
- Daho, M. E. H., Settouti, N., Lazouni, M. E. A., ve Chikh, M. E. A. (2014). Weighted vote for trees aggregation in random forest. In *2014 International Conference on Multimedia Computing and Systems (ICMCS)* (pp. 438-443). IEEE.
- Dandıl, E., ve Serin, Z. (2020). Derin Sinir Ağları Kullanarak Histopatolojik Görüntülerde Meme Kanseri Tespiti. *Avrupa Bilim ve Teknoloji Dergisi*, 451-463.
- Das, S. K., Roy, P., ve Mishra, A. K. (2022). DFU_SPNet: A stacked parallel convolution layers based CNN to improve Diabetic Foot Ulcer classification. *ICT Express*, 8(2), 271-275.
- Day, O., ve Khoshgoftaar, T. M. (2017). A survey on heterogeneous transfer learning. *Journal of Big Data*, 4, 1-42.

- Diker, A. (2020). Sıtma hastalığının sınıflandırılmasında evrişimsel sinir ağlarının performanslarının karşılaştırılması. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 9(4), 1825-1835.
- Dinov, I. D. (2018). Decision tree divide and conquer classification. *Data Science and Predictive Analytics: Biomedical and Health Applications using R*, 307-343.
- Ekanayake, I. U., Palitha, S., Gamage, S., Meddage, D. P. P., Wijesooriya, K., ve Mohotti, D. (2023). Predicting adhesion strength of micropatterned surfaces using gradient boosting models and explainable artificial intelligence visualizations. *Materials Today Communications*, 106545.
- Erdem, E., ve Aydın, T. (2021). Göğüs Kanseri Histopatolojik Görüntü Sınıflandırması. *Bilişim Teknolojileri Dergisi*, 14(1), 87-94.
- Fan, D., Sun, H., Yao, J., Zhang, K., Yan, X., ve Sun, Z. (2021). Well production forecasting based on ARIMA-LSTM model considering manual operations. *Energy*, 220, 119708.
- Fenner F, Bachmann A, Gibbs J, Murphy A, Studdert J., ve White O. (1987). *Veterinary Virology*, Academic Press Inc, London.
- Fernández, A., García, S., Galar, M., Prati, R. C., Krawczyk, B., ve Herrera, F. (2018). *Learning from imbalanced data sets* (Vol. 10, pp. 978-3). Cham: Springer.
- Firdaus, F., Abdullah, J.F., Adamu, L.H., Osman, A.Y., Haron, A.W., ve Saharee, A.A. (2013). *Clinical Management of Stage III Infectious Bovine Keratoconjunctivitis associated with Staphylococcus aureus in a dairy cow: A Case Report*.
- Freund, Y., ve Schapire, R. E. (1995). A desicion-theoretic generalization of on-line learning and an application to boosting. In *European conference on computational learning theory* (pp. 23-37). Berlin, Heidelberg: Springer Berlin Heidelberg.
- Friedman, J. H. (2001). Greedy function approximation: a gradient boosting machine. *Annals of statistics*, 1189-1232.
- Fuentes, S., Gonzalez Viejo, C., Cullen, B., Tongson, E., Chauhan, S. S., ve 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.
- George, L. W. (1990). Antibiotic treatment of infectious bovine keratoconjunctivitis. *The Cornell veterinarian*, 80(3), 229-235.
- Geurts, P., Ernst, D., ve Wehenkel, L. (2006). Extremely randomized trees. *Machine learning*, 63, 3-42.
- Ghahramani, Z. (2003). Unsupervised learning. In *Summer school on machine learning* (pp. 72-112). Berlin, Heidelberg: Springer Berlin Heidelberg.

- Ghosh, S., Dasgupta, A., ve Swetapadma, A. (2019). A study on support vector machine based linear and non-linear pattern classification. In *2019 International Conference on Intelligent Sustainable Systems (ICISS)* (pp. 24-28). IEEE.
- Grandini, M., Bagli, E., ve Visani, G. (2020). Metrics for multi-class classification: an overview. *arXiv preprint arXiv:2008.05756*.
- Grossberg, S. (2013). Recurrent neural networks. *Scholarpedia*, 8(2), 1888.
- Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., ve Chen, T. (2018). Recent advances in convolutional neural networks. *Pattern recognition*, 77, 354-377.
- Guan, Q., Wang, Y., Ping, B., Li, D., Du, J., Qin, Y., ve Xiang, J. (2019). Deep convolutional neural network VGG-16 model for differential diagnosing of papillary thyroid carcinomas in cytological images: a pilot study. *Journal of Cancer*, 10(20), 4876.
- Gunn, S. R. (1998). Support vector machines for classification and regression. *ISIS technical report*, 14(1), 5-16.
- Guryanov, A. (2019, July). Histogram-Based Algorithm for Building Gradient Boosting Ensembles of Piecewise Linear Decision Trees. In *International Conference on Analysis of Images, Social Networks and Texts* (pp. 39-50).
- Hailu, B., Alemayehu, G., ve Seid, N. (2015). Epidemiology, economic importance and control techniques of lumpy skin diseases. *Anim. Vet. Sci*, 3(2), 58-66.
- Harshaw Kamal, S., Ragul Raj, R. K., Sabari, T., ve Karthika, R. (2022). Performance Analysis of Different Deep Learning Models for Forest Fire Classification. In *Disruptive Technologies for Big Data and Cloud Applications: Proceedings of ICBDDC 2021* (pp. 143-151). Singapore: Springer Nature Singapore.
- Hasib, F. M. Y., Islam, M. S., Das, T., Rana, E. A., Uddin, M. H., Bayzid, M., ve Alim, M. A. (2021). Lumpy skin disease outbreak in cattle population of Chattogram, Bangladesh. *Veterinary Medicine and Science*, 7(5), 1616-1624.
- Hassanat, A. B. (2018). Furthest-pair-based binary search tree for speeding big data classification using k-nearest neighbors. *Big Data*, 6(3), 225-235.
- He, H., ve Garcia, E. A. (2009). Learning from imbalanced data. *IEEE Transactions on knowledge and data engineering*, 21(9), 1263-1284.
- Holzhauer, M., Visser, I. J., ve Van Maanen, K. (2004). Infectious bovine keratoconjunctivitis (IBK) in cows, clinical and lab review at four farms. *Tijdschrift voor diergeneeskunde*, 129(16), 526-529.
- Hopfield, J. J. (1988). Artificial neural networks. *IEEE Circuits and Devices Magazine*, 4(5), 3-10.
- Hossin, M., ve Sulaiman, M. N. (2015). A review on evaluation metrics for data classification evaluations. *International journal of data mining & knowledge management process*, 5(2), 1.

- Howard, A., Sandler, M., Chu, G., Chen, L. C., Chen, B., Tan, M., ve Adam, H. (2019). Searching for mobilenetv3. In *Proceedings of the IEEE/CVF international conference on computer vision* (pp. 1314-1324).
- Huang, G., Liu, Z., Van Der Maaten, L., ve Weinberger, K. Q. (2017). Densely connected convolutional networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4700-4708).
- Iliev, N., ve Trivedi, A. R. (2020). Low latency CMOS hardware acceleration for fully connected layers in deep neural networks. *arXiv preprint arXiv:2011.12839*.
- Işık, N. (2008). İnfeksiyöz Bovine Keratokonjunktivitisi Sığırlarda Moraxella bovis' in İzolasyonu ve Antibiyotiklere Duyarlılığının Araştırılması. *Dicle Üniversitesi Veteriner Fakültesi Dergisi*, (1), 17-22.
- İnce, Ö. B., ve Kanat, Ö. (2015). Şap Hastalığı. *Etlik Veteriner Mikrobiyoloji Dergisi*, 26(2), 45-51.
- Jain, A. K., Mao, J., ve Mohiuddin, K. M. (1996). Artificial neural networks: A tutorial. *Computer*, 29(3), 31-44.
- Jelinek, F., ve Tachezy, R. (2005). Cutaneous papillomatosis in cattle. *Journal of Comparative Pathology*, 132(1), 70-81.
- Jingqiu, G., Zhihai, W., Ronghua, G., ve Huarui, W. (2017). Cow behavior recognition based on image analysis and activities. *International Journal of Agricultural and Biological Engineering*, 10(3), 165-174.
- Jubb, K. V. F., Kennedy, P. C., ve Palmer, N. (2006). Foot and mouth disease. In *"Pathology of Domestic Animals", 5 th ed.*, Academic Press Inc. Ltd. London, 135-137.
- Kaelbling, L. P., Littman, M. L., ve Moore, A. W. (1996). Reinforcement learning: A survey. *Journal of artificial intelligence research*, 4, 237-285.
- Karaman, M., ve ÇINAR, S. (2022). Abdominal bilgisayarlı tomografi görüntülerinde böbrek taşlarının sınırlarının ve sayılarının görüntü işleme yöntemleri kullanılarak tespiti. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 11(1).
- Kavyashree, P. S., ve El-Sharkawy, M. (2021). Compressed mobilenet v3: A light weight variant for resource-constrained platforms. In *2021 IEEE 11th Annual Computing and Communication Workshop and Conference (CCWC)* (pp. 0104-0107). IEEE.
- King, A. M. Q., Brown, F., Christian, P., Hovi, T., Hyypia, T., Knowles, N. J., ve Stanway, G. (2000). Virus taxonomy seventh report of the International Committee for the Taxonomy of Viruses. In *Picornaviridae* (pp. 657-673). Academic Press, New York and San Diego, CA.
- Kingsford, C., ve Salzberg, S. L. (2008). What are decision trees?. *Nature biotechnology*, 26(9), 1011-1013.

- Krutsch, R., ve Tenorio, D. (2011). Histogram equalization. *Freescale Semiconductor, Document Number AN4318*, Application Note.
- Kumar, V. B., Kumar, S. S., ve Saboo, V. (2016). Dermatological disease detection using image processing and machine learning. In *2016 Third International Conference on Artificial Intelligence and Pattern Recognition (AIPR)* (pp. 1-6). IEEE.
- Lancaster, W. D., ve Olson, C. (1982). Animal papillomaviruses. *Microbiological Reviews*, 46(2), 191-207.
- Li, L., Zhang, S., ve Wang, B. (2021). Apple leaf disease identification with a small and imbalanced dataset based on lightweight convolutional networks. *Sensors*, 22(1), 173.
- Lopez, M. M., ve Kalita, J. (2017). Deep Learning applied to NLP. *arXiv preprint arXiv:1703.03091*.
- Maclachlan, N. J., Dubovi, E. J., ve Fenner, F. (2011). *Fenner's veterinary virology* (No. 11031). Elsevier Academic Press.
- Mammone, A., Turchi, M., ve Cristianini, N. (2009). Support vector machines. *Wiley Interdisciplinary Reviews: Computational Statistics*, 1(3), 283-289.
- Medsker, L. R., ve Jain, L. C. (2001). Recurrent neural networks. *Design and Applications*, 5, 64-67.
- Moore C. P. (2002). Diseases of eye. Smith BP. ed. *Large Animal Internal Medicine. Third Edition*. St. Louis: Mosby, 1168-1170.
- Munday, J. S. (2014). Bovine and human papillomaviruses: a comparative review. *Veterinary pathology*, 51(6), 1063-1075.
- Nagi, J., Ducatelle, F., Di Caro, G. A., Cireşan, D., Meier, U., Giusti, A., ve Gambardella, L. M. (2011). Max-pooling convolutional neural networks for vision-based hand gesture recognition. In *2011 IEEE international conference on signal and image processing applications (ICSIPA)* (pp. 342-347). IEEE.
- Natekin, A., ve Knoll, A. (2013). Gradient boosting machines, a tutorial. *Frontiers in neurorobotics*, 7, 21.
- Naz, S., Ashraf, A., ve Zaib, A. (2022). Transfer learning using freeze features for Alzheimer neurological disorder detection using ADNI dataset. *Multimedia Systems*, 28(1), 85-94.
- Nicholls, P. K., ve Stanley, M. A. (2000). The immunology of animal papillomaviruses. *Veterinary immunology and immunopathology*, 73(2), 101-127.
- Noble, W. S. (2006). What is a support vector machine?. *Nature biotechnology*, 24(12), 1565-1567.

- Oktradiksa, A., Bhakti, C. P., Kurniawan, S. J., ve Rahman, F. A. (2021). Utilization artificial intelligence to improve creativity skills in society 5.0. In *Journal of Physics: Conference Series* (Vol. 1760, No. 1, p. 012032). IOP Publishing.
- Or, M., Bakırel, U., Tuncel, H., Arun, S., Karakoç, Y., Dodurka, H., ve Barutçu, Ü. (2002). Deri Hastalıklı Köpeklerde Serum Çinko ve Bakır Düzeyleri ile Histopatolojik Değişikliklerin İlişkisi. *İstanbul Üniversitesi Veteriner Fakültesi Dergisi*, 28(2), 337-345.
- O'Shea, K., ve Nash, R. (2015). An introduction to convolutional neural networks. *arXiv preprint arXiv:1511.08458*.
- Otter, A., ve Leonard, D. (2003). Fibropapillomatosis outbreak in calves. *The Veterinary record*, 153(18), 570-571.
- Oury, M. P., Scharko, P., ve Johns, J. (2002). Pinkeye in cattle. *Kentucky: Cooperative Extension Services*, 135.
- Özgünlük, İ. (2015). Sığırların Nodüler Ekzantemi. *Harran Üniversitesi Veteriner Fakültesi Dergisi*, 4(2), 94-99.
- Peterson, L. E. (2009). K-nearest neighbor. *Scholarpedia*, 4(2), 1883.
- Qian, S., Liu, H., Liu, C., Wu, S., ve San Wong, H. (2018). Adaptive activation functions in convolutional neural networks. *Neurocomputing*, 272, 204-212.
- Quinn PJ, Carter ME, Markey B., ve Carter GR. (2002). *Clinical Veterinary Microbiology*. 284-286, Ed. Mosby, Edinburgh Scotland.
- Rachna, H. B., ve Swamy, M. M. (2013). Detection of Tuberculosis bacilli using image processing techniques. *International Journal of Soft Computing and Engineering (IJSCE)*, 3(4), 2231-2307.
- Ren, X., Guo, H., Li, S., Wang, S., ve Li, J. (2017). A novel image classification method with CNN-XGBoost model. In *Digital Forensics and Watermarking: 16th International Workshop, IWDW 2017, Magdeburg, Germany, August 23-25, 2017, Proceedings 16* (pp. 378-390). Springer International Publishing.
- Rony, M., Barai, D., ve Hasan, Z. (2021). Cattle external disease classification using Deep Learning Techniques. In *2021 12th International Conference on Computing Communication and Networking Technologies (ICCCNT)* (pp. 1-7). IEEE.
- Salehi, H., ve Burgueño, R. (2018). Emerging artificial intelligence methods in structural engineering. *Engineering structures*, 171, 170-189.
- Santra, A. K., ve Christy, C. J. (2012). Genetic algorithm and confusion matrix for document clustering. *International Journal of Computer Science Issues (IJCSI)*, 9(1), 322.
- Schaefer, A. L., Cook, N., Tessaro, S. V., Deregt, D., Desroches, G., Dubeski, P. L., ve Godson, D. L. (2004). Early detection and prediction of infection using infrared thermography. *Canadian journal of animal science*, 84(1), 73-80.


- Schapire, R. E. (2013). Explaining adaboost. In *Empirical Inference: Festschrift in Honor of Vladimir N. Vapnik* (pp. 37-52). Berlin, Heidelberg: Springer Berlin Heidelberg.
- Segal, M. R. (2004). Machine learning benchmarks and random forest regression.
- Shoeibi, A., Ghassemi, N., Heras, J., Rezaei, M., ve Gorriz, J. M. (2022). Automatic diagnosis of myocarditis in cardiac magnetic images using CycleGAN and deep PreTrained models. In *International work-conference on the interplay between natural and artificial computation* (pp. 145-155). Cham: Springer International Publishing.
- Slatter, D. H., Edwards, M. E., Hawkins, C. D., ve Wilcox, G. E. (1982). A national survey of the occurrence of infectious bovine keratoconjunctivitis. *Australian Veterinary Journal*, 59(3), 65-68.
- Snowder, G. D., Van Vleck, L. D., Cundiff, L. V., ve Bennett, G. L. (2005). Genetic and environmental factors associated with incidence of infectious bovine keratoconjunctivitis in preweaned beef calves. *Journal of animal science*, 83(3), 507-518.
- Soni, A. N. (2018). Application and analysis of transfer learning-survey. *International Journal of Scientific Research and Engineering Development*, 1(2), 272-278.
- Stefenon, S. F., Yow, K. C., Nied, A., ve Meyer, L. H. (2022). Classification of distribution power grid structures using inception v3 deep neural network. *Electrical Engineering*, 104(6), 4557-4569.
- Sutskever, I. (2013). *Training recurrent neural networks* (pp. 1-101). Toronto, ON, Canada: University of Toronto.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., ve Wojna, Z. (2016). Rethinking the inception architecture for computer vision. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2818-2826).
- Tammina, S. (2019). Transfer learning using vgg-16 with deep convolutional neural network for classifying images. *International Journal of Scientific and Research Publications (IJSRP)*, 9(10), 143-150.
- Tan, C., Sun, F., Kong, T., Zhang, W., Yang, C., ve Liu, C. (2018). A survey on deep transfer learning. In *Artificial Neural Networks and Machine Learning-ICANN 2018: 27th International Conference on Artificial Neural Networks, Rhodes, Greece, October 4-7, 2018, Proceedings, Part III* 27 (pp. 270-279). Springer International Publishing.
- Tharwat, A. (2020). Classification assessment methods. *Applied computing and informatics*, 17(1), 168-192.
- Toğaçar, M., Ergen, B., ve Sertkaya, M. E. (2019). Zatürre Hastalığının Derin Öğrenme Modeli ile Tespiti. *Firat University Journal of Engineering*, 31(1).

- Truica, C. O., ve Leordeanu, C. A. (2017). Classification of an imbalanced data set using decision tree algorithms. *Univ. Politech. Bucharest Sci. Bull. Ser. C Electr. Eng. Comput. Sci*, 79, 69-84.
- Tufan, M. (2006). Animal health authorities and transboundary animal diseases in Turkey. *Journal of Veterinary Medicine, Series B*, 53, 35-37.
- Uçar, M. (2021). Glokom Hastalığının Evrişimli Sinir Ağı Mimarileri ile Tespiti. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 23(68), 521-529.
- Uzun, S. (2020). Bölgesel-Evrişimsel Sinir Ağları ile Retina Görüntülerindeki Lezyonların Tespiti. *Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Dergisi*, 7(1), 34-46.
- Vijayalakshmi, M. M. (2019). Melanoma skin cancer detection using image processing and machine learning. *International Journal of Trend in Scientific Research and Development (IJTSRD)*, 3(4), 780-784.
- Vorster, H., ve Mapham, H. (2008). Pathology of lumpy skin disease. *Livest Hilth Prod Rev*, 1, 16-21.
- Wu, S., ve Flach, P. (2005). A scored AUC metric for classifier evaluation and selection. In *Second workshop on ROC analysis in ML, Bonn, Germany*.
- Xu, J., Pan, Y., Pan, X., Hoi, S., Yi, Z., ve Xu, Z. (2022). RegNet: self-regulated network for image classification. *IEEE Transactions on Neural Networks and Learning Systems*.
- Yao, D., Li, G., Liu, H., ve Yang, J. (2021). An intelligent method of roller bearing fault diagnosis and fault characteristic frequency visualization based on improved MobileNet V3. *Measurement Science and Technology*, 32(12), 124009.
- Yegnanarayana, B. (2009). *Artificial neural networks*. PHI Learning Pvt. Ltd..
- Yu, Y., Si, X., Hu, C., ve Zhang, J. (2019). A review of recurrent neural networks: LSTM cells and network architectures. *Neural computation*, 31(7), 1235-1270.
- Zhang, Z., ve Sabuncu, M. (2018). Generalized cross entropy loss for training deep neural networks with noisy labels. *Advances in neural information processing systems*, 31.
- Zhao, K., Bewley, J. M., He, D., ve Jin, X. (2018). Automatic lameness detection in dairy cattle based on leg swing analysis with an image processing technique. *Computers and Electronics in Agriculture*, 148, 226-236.
- Zheng, T., Yang, X., Lv, J., Li, M., Wang, S., ve Li, W. (2023). An efficient mobile model for insect image classification in the field pest management. *Engineering Science and Technology, an International Journal*, 39, 101335.
- Zhu, Y., ve Newsam, S. (2017). Densenet for dense flow. In *2017 IEEE international conference on image processing (ICIP)* (pp. 790-794). IEEE.


Zoph, B., Vasudevan, V., Shlens, J., ve Le, Q. V. (2018). Learning transferable architectures for scalable image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 8697-8710).



EKLER



EK 1 - Şekil 0.1. Mobil uygulama ve web servis uygulama şeması



EK 2 - Şekil 0.2. Bu çalışmada uygulanan materyal ve yöntemlerin şeması