

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

SIĞIR AKCİĞERİNDE PNÖMONİLERİN VE
TÜBERKÜLOZ HASTALIĞININ
HİSTOPATOLOJİK VERİLER KULLANILARAK
MAKİNE ÖĞRENMESİ TEKNİKLERİYLE
TESPİTİ

Ali ÇELİK

Danışman: Prof. Dr. İsmail KIRBAŞ
II. Danışman: Dr. Öğr. Üyesi Osman Tayfun BİŞKİN

BURDUR, 2024

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 Akciğerinde Pnömonilerin ve Tüberküloz Hastalığının Histopatolojik Veriler Kullanılarak Makine Öğrenmesi Teknikleriyle Tespiti”** 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.

06/08/2024

(İmza)

Ali ÇELİK

ÖNSÖZ

Bu tez çalışması, uzun ve zorlu bir akademik yolculuğun ürünüdür. Bu süreçte bana destek olan ve katkıda bulunan herkese minnettarım.

Tez danışmanım Sayın **Prof. Dr. İsmail KIRBAŞ**'a, bu çalışma boyunca gösterdiği rehberlik ve sabır için derin teşekkürlerimi sunarım. Eş danışmanım Sayın **Dr. Öğr. Üyesi Osman Tayfun BİŞKİN**'in değerli katkıları ve yönlendirmeleri için kendisine müteşekkirim.

Prof. Dr. Özlem Özmen'e, süreç boyunca sağladığı tavsiyeleri için özel bir teşekkür borçluyum.

Jüri üyelerine, değerli zamanlarını ayırıp tezimi değerlendirdikleri ve yapıcı geri bildirimleriyle çalışmamı geliştirmeme yardımcı oldukları için şükranlarımı sunarım.

Burdur Mehmet Akif Ersoy Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğü'ne, 0895-YL-23 No'lu Proje kapsamında sağladıkları maddi destek için ayrıca teşekkür ederim.

Bu zorlu süreçte en büyük destekçim olan aileme sonsuz sevgilerimi sunuyorum. Sevgili eşim, anlayışın ve sabrın için ne kadar minnettar olduğumu kelimelerle ifade etmem mümkün değil. Varlığınız bu yolculuğu anlamlı kıldı.

Bu tezi, hayatımıza neşe ve anlam katan sevgili oğlum BURAK'a ithaf ediyorum. Senin varlığın, bu çalışmayı tamamlamamda en büyük motivasyon kaynağım oldu.

Son olarak, burada isimlerini tek tek sayamadığım, ancak bu süreçte bana destek olan tüm arkadaşlarıma, meslektaşlarıma ve diğer kıymetli insanlara içten teşekkürlerimi sunarım.

Ağustos, 2024

Ali ÇELİK

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	4
2.1. Literatür Özeti	4
2.2. Yapay Zeka	6
2.3. Makine Öğrenmesi	7
2.4. Derin Öğrenme	8
2.5. Performans Metrikleri	9
3. MATERYAL VE YÖNTEM	12
3.1. Materyal	12
3.1.1. Veri Seti	12
3.1.2. Yazılımlar ve Araçlar	13
3.1.3. Donanım	13
3.2. Histopatoloji Yöntemi	13
3.3. Makine Öğrenmesi Yöntemleri	14
3.3.1. Lojistik Regresyon	14
3.3.2. Destek Vektör Makineleri (DVM)	15
3.3.3. Rastgele Orman	17
3.3.4. Naive Bayes	19
3.4. Derin Öğrenme Yöntemleri	20
3.4.1. Evrişimli Sinir Ağları	20
3.4.2. Öğrenim Aktarımı (Transfer Learning)	24
3.4.3. ResNet-50	25
3.4.4. You Look Only Once (YOLO)	26
3.5. Veri İşleme ve Model Geliştirme	30
4. ARAŞTIRMA BULGULARI VE TARTIŞMA	34
5. SONUÇ VE ÖNERİLER	40
KAYNAKLAR	43

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 2.1. Yapay zeka ve alt dalları	7
Şekil 2.2. Makine öğrenmesi türleri	8
Şekil 2.3. Basit bir yapay sinir ağı gösterimi	9
Şekil 2.4. Etiketlenmiş bölge ile tahmin edilen bölgelerin birleşim ve kesişim alanları	11
Şekil 3.1. Sırasıyla tüberküloz, pnömoni ve sağlıklı doku örnekleri.....	13
Şekil 3.2. Lojistik regresyonun olasılık eğrisi.....	15
Şekil 3.3. Üç boyutlu uzayda ikili sınıflandırma ve ayırıcı hiperdüzlem	16
Şekil 3.4. DVM'in İki boyutlu uzayda sınıflandırma mekanizması: Hiperdüzlem, marjin ve destek vektörleri	17
Şekil 3.5. Rastgele orman algoritmasının sınıflandırma görevi için çalışma mekanizması.....	19
Şekil 3.6. Evrişimli sinir ağı mimarisi örneği	21
Şekil 3.7. 5×5 Renkli bir görüntü üzerine evrişim işleminin uygulanışı.....	22
Şekil 3.8. Görüntü üzerine dolgu tekniğinin uygulanışı	22
Şekil 3.9. Havuzlama metodunun uygulanışı.....	23
Şekil 3.10. Öğrenim aktarımı metodunun şematik gösterimi.	25
Şekil 3.11. ResNet-50'nin mimarisi.	26
Şekil 3.12. YOLOv8'in mimarisi.	28
Şekil 3.13. Hücrelere bölünmüş bir görüntü ve 61. hücre için çıkış verileri. Çıkış verisi her bir hücre için hesaplanır	29
Şekil 3.14. Çalışmanın metodolojisinin şematik gösterimi.....	33
Şekil 4.1. bTB'den etkilenen akciğerlerin makroskopik görünümü.	34
Şekil 4.2. Üç farklı önceden eğitilmiş YOLOv8 modelinin parametre sayısının karşılaştırması.....	35
Şekil 4.3. Tüberküloz veri seti üzerine eğitilmiş üç YOLO modelinin IoU 0.50'deki ortalama kesinlik (mAP50) dağılımı	35
Şekil 4.4. Tüberküloz veri seti üzerine eğitilmiş üç farklı YOLO modelinin (x-large large ve medium) duyarlılık değerlerinin döngü sayısına (epoch) göre değişimi.....	36

Şekil 4.5. Tüberküloz veri seti üzerine eğitilmiş üç farklı YOLO modelinin kesinlik değerlerinin döngü sayısına göre değişimi.....	36
Şekil 4.6. Lojistik regresyon modelinin tüberküloz ve pnömoni sınıflarını sınıflandırma performansını gösteren karmaşıklık matrisi.....	37
Şekil 4.7. Lojistik regresyon modelinin tüberküloz ve pnömoni sınıflarını ayırt etme performansını gösteren ROC eğrisi	37
Şekil 4.8. Üç farklı YOLO modelinin Langhans hücrelerini tespit etme durumu ve güven skorları.....	39



ÇİZELGELER DİZİNİ

Sayfa

Çizelge 3.1. Lojistik Regresyon, Destek Vektör Makineleri, Rastgele Orman ve Naïve Bayes algoritmaları için GridSearch ile optimize edilen hiperparametreler	32
Çizelge 4.1. Tüberküloz ve pnömoni sınıflandırması için eğitilmiş modellerin performans metrikleri	38



SİMGELER VE KISALTMALAR DİZİNİ

AUC	: Area Under Curve
bTB	: Sığır Tüberkülozu
BT	: Bilgisayarlı Tomografi
ESA	: Evrişimli Sinir Ağları
DDİ	: Doğal Dil İşleme
DÖ	: Derin Öğrenme
DVM	: Destek Vektör Makineleri
KBO	: Kesişim Birleşim Oranı
LR	: Lojistik Regresyon
MAKÜ	: Burdur Mehmet Akif Ersoy Üniversitesi
MÖ	: Makine Öğrenimi
RNN	: Tekrarlayan Sinir Ağları
RO	: Rastgele Orman
SGD	: Stokastik Gradyan İnişi
tB	: Tüberküloz
YOLO	: You Look Only Once
YZ	: Yapay Zeka

ÖZET

Yüksek Lisans Tezi

Sığır Akciğerinde Pnömonilerin ve Tüberküloz Hastalığının Histopatolojik Veriler Kullanılarak Makine Öğrenmesi Teknikleriyle Tespiti

Ali Çelik

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

Danışman: Prof. Dr. İsmail KIRBAŞ
II. Danışman: Dr. Öğr. Üyesi Osman Tayfun BİŞKİN

Ağustos, 2024

Sığır tüberkülozu (bTB), önemli ekonomik kayıplarla ilişkilendirilen, zoonotik, bulaşıcı ve kronik bir hastalıktır ve dünya genelinde çeşitli bölgelerde endemik bir sorun olarak varlığını sürdürmektedir. Histopatolojik incelemeler, özellikle ayırt edici bir belirteç olarak işlev gören Langhans dev hücrelerinin tanımlanmasıyla, kritik bir teşhis yöntemidir. Bu çalışma, öğrenim aktarımını kullanarak tüberkülozun diğer pnömoni türlerinden ayırıcı tanısına odaklanmaktadır. Ayrıca, çalışma, histopatolojik görüntülerde Langhans dev hücrelerini tespit etmek için YOLOv8 algoritmasını kullanarak bTB teşhisini geliştirmeyi amaçlamaktadır. Lojistik Regresyon (LR), Destek Vektör Makineleri (DVM) ve Rastgele Orman (RO) gibi makine öğrenmesi algoritmaları sınıflandırma görevinde %98.6'lık dikkate değer bir doğruluk gösterirken, YOLOv8 Langhans dev hücrelerini lokalize etmede yüksek hassasiyet sergilemektedir. Bu bulgular, özellikle tüberkülozun diğer akciğer rahatsızlıklarından ayırt edilmesinde, bTB teşhis yeteneklerinin ilerlemesine değerli bir katkı sağlamaktadır.

Anahtar Kelimeler: tüberküloz, pnömoni, makine öğrenmesi, öğrenim aktarımı, YOLOv8

Hazırlanan bu Yüksek Lisans tezi Burdur Mehmet Akif Ersoy Üniversitesi Bilimsel Araştırma Projeleri Birimi tarafından 0895-YL-23 proje numarası ile desteklenmiştir.

ABSTRACT

M.Sc. Thesis

Detection of Pneumonia and Tuberculosis Disease in the Bovine Lung by Machine Learning Techniques Using Histopathological Data

Ali elik

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

**Supervisor: Prof. Dr. İsmail Kırbaşı
Co-Supervisor: Asst. Prof. Dr. Osman Tayfun Bişkin**

August, 2024

Bovine tuberculosis (bTB) is a zoonotic, infectious, and chronic disease associated with significant economic losses, persisting as an endemic concern in various regions globally. Histopathological examinations are a crucial diagnostic method, particularly with the identification of Langhans giant cells, which act as a distinctive marker. The study focuses on the differential diagnosis of tuberculosis from other types of pneumonia utilizing transfer learning. Additionally, the work aims to enhance bTB diagnosis by employing the YOLOv8 algorithm to detect Langhans giant cells in histopathological images. While machine learning algorithms such as Logistic Regression, Support Vector Machines, and Random Forest algorithms reveal a notable accuracy of 98.6% in classification task, YOLOv8 demonstrates high precision in localizing Langhans giant cells. These findings make a valuable contribution to the advancement of bTB diagnostic capabilities, particularly in distinguishing tuberculosis from other pulmonary conditions.

Keywords: tuberculosis, pneumonia, machine learning, transfer learning, YOLOv8

The present M.Sc. Thesis was supported by Burdur Mehmet Akif Ersoy University Scientific Research Council Under the Project number of 0895-YL-23.

1. GİRİŞ

Tüberküloz (TB) ve pnömoni, dünya çapında halk sağlığını tehdit eden en önemli solunum yolu hastalıkları arasında yer almaktadır. Bu hastalıklar, erken teşhis ve doğru tedavi ile önlenabilir veya kontrol altına alınabilir olmasına rağmen, hala milyonlarca insanın hayatını etkilemekte ve her yıl önemli sayıda ölüme neden olmaktadır. Dünya Sağlık Örgütü'nün (DSÖ) 2020 yılı verilerine göre (World Health Organization, 2020), TB kaynaklı ölümlerde her yıl önemli bir artış gözlenmektedir. Bu artışın başlıca nedenleri arasında teşhisin gecikmesi, yanlış teşhis konulması ve uygun tedavinin sağlanamaması yer almaktadır. Bu nedenle, hastalığın yayılmasını önlemek, tedavi sürecini en etkili şekilde yönetmek ve ölüm oranlarını kayda değer ölçüde düşürmek için erken teşhis hayati önem taşımaktadır.

Tüberküloz, *Mycobacterium tuberculosis* bakterisinin neden olduğu, öncelikle akciğerleri hedef alan ancak vücudun diğer bölgelerini de etkileyebilen ciddi bir enfeksiyon hastalığıdır. Hastalık genellikle hava yoluyla bulaşır ve tedavi edilmediğinde ölümcül olabilir. Öte yandan pnömoni, çeşitli mikroorganizmaların neden olduğu akciğer iltihabıdır ve özellikle çocuklar, yaşlılar ve bağışıklık sistemi zayıf kişiler için ciddi bir tehdit oluşturur. Her iki hastalık da dünya genelinde yaygın olmakla birlikte, özellikle düşük ve orta gelirli ülkelerde daha yüksek ölüm oranlarıyla karşılaşılmaktadır.

Tüberküloz yalnızca insanları değil, aynı zamanda hayvanları da tehdit eden ciddi bir sağlık sorunudur. Özellikle sığırlar arasında yaygın olan sığır tüberkülozu (bTB), *Mycobacterium bovis* (*M. bovis*) adlı bakterinin neden olduğu bir hastalıktır. Bu hastalık, sığırların yanı sıra çeşitli yabani ve evcil hayvanları da etkileyebilmektedir (O'Reilly ve Daborn, 1995). İnsanlarda tüberküloz genellikle hava yoluyla, öksürme veya hapşırma gibi aktivitelerle bulaşırken, hayvanlardan insanlara geçiş farklı yollarla gerçekleşebilir. Enfekte hayvanlardan elde edilen kontamine süt, su veya süt ürünlerinin tüketimi, hastalığın yayılmasında önemli bir rol oynar. Ayrıca, hayvan kesimi sırasında bakterilerle kirlenmiş havanın solunması da bulaşma riskini artırır. Öte yandan, pnömoni ise alveollerini etkileyen bir iltihaplanma durumudur ve çeşitli nedenlere bağlı olarak ortaya çıkabilir. Viral veya bakteriyel enfeksiyonlardan otoimmün hastalıklara kadar geniş bir yelpazede pnömoniye yol açan etkenler bulunmaktadır. Sığır popülasyonlarında pnömoni, tüm yaş gruplarını etkileyen yaygın bir solunum yolu hastalığıdır. Bu hastalığa mantarlar, bakteriler ve virüsler gibi çeşitli bulaşıcı etmenler neden olabilir. Sığırlarda pnömoniye yol açan başlıca bakteriyel etkenler arasında *Histophilus somni*, *Mannheimia*

haemolytica ve Pasteurella multocida sayılabilir. Sığırlarda pnömoni belirtileri arasında hırıltılı solunum, burun akıntısı, yüksek ateş ve nefes almada zorluk gibi klinik semptomlar gözlemlenebilir. Ancak, düzenli aşılama programları, uygun havalandırma koşullarının sağlanması ve bulaşıcı etkenlere maruz kalmanın en aza indirilmesi gibi önleyici tedbirlerle sığırlarda bu enfeksiyonların görülme sıklığı önemli ölçüde azaltılabilir.

Tüberküloz ve pnömoni teşhisinde, göğüs röntgenleri gibi tıbbi görüntüleme teknikleri kritik bir rol oynamaktadır. Bu görüntüler, hastalığın varlığını, şiddetini ve ilerleyişini değerlendirmede önemli bilgiler sağlar. Ancak, bu görüntülerin analizi zaman alıcı olabilir ve uzman yorumlaması gerektirebilir. Ayrıca, özellikle kaynak kısıtlı bölgelerde uzman radyolog eksikliği, teşhis sürecini daha da zorlaştırmaktadır. Bu zorluklar, hastalıkların erken teşhisini ve dolayısıyla etkili tedavisini engelleyebilmektedir.

Yapay zeka (YZ) ve makine öğrenmesi teknolojileri, tıbbi görüntü analizinde devrim niteliğinde gelişmelere yol açmıştır. Bu teknolojiler, göğüs röntgenlerinin hızlı ve doğru bir şekilde analiz edilmesine, hastalıkların erken teşhis edilmesine ve tedavi süreçlerinin optimize edilmesine olanak sağlamaktadır. YZ destekli sistemler, insan gözünün kaçırabileceği ince detayları tespit edebilme, büyük veri setlerini hızla analiz edebilme ve tutarlı sonuçlar üretebilme yetenekleriyle öne çıkmaktadır.

YZ teknolojilerinin tıbbi görüntü analizindeki bu başarıları, sağlık hizmetlerinin sunumunda önemli değişikliklere yol açma potansiyeline sahiptir. Bu sistemler, radyologların iş yükünü azaltabilir, teşhis sürecini hızlandırabilir ve özellikle uzman sağlık personelinin sınırlı olduğu bölgelerde sağlık hizmetlerine erişimi iyileştirebilir. Ayrıca, bu teknolojiler, hastalıkların erken evrelerde tespit edilmesini sağlayarak, tedavi başarısını artırabilir ve sağlık sistemleri üzerindeki yükü azaltabilir.

Bu çalışmanın amacı, histopatolojik preparatlarda Langhans dev hücrelerinin YZ yöntemleri ile tespit edilmesidir. Langhans dev hücreleri, özellikle tüberküloz gibi hastalıkların tanısında önemli bir belirteçtir. Bu hücrelerin YZ ile otomatik olarak tespit edilmesi, tanı sürecini hızlandırabilir ve doğruluğunu artırabilir. Çalışma, mevcut literatürü gözden geçirerek, bu teknolojilerin tıbbi görüntü analizindeki uygulamalarını, avantajlarını ele alacaktır. Bu gelişmelerin, patoloji alanında birkaç önemli etkisi olması beklenmektedir:

- Uzmanların iş yükünün azaltılması: YZ sistemleri, rutin ve tekrar eden görevleri üstlenerek patoloğların daha karmaşık ve kritik vakalara odaklanmalarına olanak sağlayabilir.
- Patoloji raporlarının nesnelliğinin ve tutarlılığının artırılması: YZ tabanlı analizler, insan faktöründen kaynaklanan değişkenlikleri en aza indirerek daha standart ve tekrarlanabilir sonuçlar sunabilir.
- Gizli bilgilerin ortaya çıkarılması: YZ algoritmaları, insan gözünün kaçırabileceği veya fark edemeyeceği örüntüleri tespit ederek, mevcut verilerden yeni ve potansiyel olarak klinik açıdan önemli bilgiler çıkarabilir.



2. GENEL BİLGİLER

Bu bölümde yapay zeka destekli çalışmaların geniş bir literatür taramasını verilecek, aynı zamanda yapay zeka ve türleri hakkında bilgiler sunulacaktır.

2.1. Literatür Özeti

Literatürde, pnömoni veya tüberküloz gibi hastalıkların teşhisine yönelik çok sayıda çalışma bulunmaktadır. Bu araştırmalar, söz konusu alandaki kayda değer gelişmeleri gözler önüne sermektedir (Kant ve Srivastava, 2018; Panicker vd., 2018; Becker vd., 2018; Kuo vd., 2019; Mollenhorst vd., 2019; Pereira vd., 2020; Rahman vd., 2020; Zak ve Krzyżak, 2020; More vd., 2021; Stański vd., 2021; Bhartiya vd., 2021; Puttagunta ve Ravi, 2021; Bokkolla vd., 2021; Patel vd., 2021; Račić vd., 2021; Venkataramana vd., 2022; Bangare vd., 2022; Mwendo vd., 2023). Bu yoğun araştırma faaliyetleri, sadece yenilikçi teknolojilerin geliştirilmesine katkıda bulunmakla kalmayıp, aynı zamanda kritik tıbbi durumlarda teşhis yeteneklerini de önemli ölçüde iyileştirmektedir.

Makine öğrenimi (MÖ) algoritmaları, günümüzde çok çeşitli alanlarda uygulanmaktadır. Görüntü tanıma, konuşma tanıma, sınıflandırma, tahmin ve tıbbi teşhis gibi birçok alanda bu algoritmalar etkin bir şekilde kullanılmaktadır (Deng ve Platt, 2014; Noda vd., 2015; Wu ve Chen, 2015; Shen vd., 2017; Ker vd., 2018; Fujiyoshi vd., 2019; Chan vd., 2020; Celik ve Seveli, 2022; Celik, 2023; 2024). Özellikle tıp alanında, makine öğrenimi yöntemleri büyük bir ilerleme kaydetmiştir. Bu yöntemler, tıbbi teşhislerin doğruluğunu ve genel kalitesini artırmada önemli bir rol oynamaktadır. Böylece, makine öğrenimi algoritmaları, tıp alanında daha hızlı, daha doğru ve daha etkili teşhis yöntemlerinin geliştirilmesine öncülük etmektedir.

Akciğer hastalıklarını tanımlamak için göğüs röntgeni görüntülerini kullanan Stański vd. (2021), sınırlı veri setleri ve derin öğrenme modelleri kullanılmıştır. Bu çalışmadaki süreç iki aşamadan oluşmaktaydı: akciğer segmentasyonu ve hastalık sınıflandırması. Akciğer segmentasyonu için U-net modeli kullanılmış ve görüntülerden akciğerlerin belirli bölümleri çıkarılmıştır. Hastalık sınıflandırması, önceden eğitilmiş üç evrişimli sinir ağı (ESA) VGG16, ResNet-50 ve InceptionV3 kullanılarak gerçekleştirilmiş ve hem segmente edilmiş hem de edilmemiş görüntüler üzerinde ince ayar yapılmıştır. Yöntemin performansı Shenzhen Hastanesi ve Montgomery veri kümeleri üzerinde test edilmiştir. Araştırma, literatürdeki mevcut çözümlere kıyasla

tüberküloz ve pnömoni tespiti için yüksek doğruluk ve AUC skorları bildirmiştir. Önceden eğitilmiş InceptionV3 modeli için sağlıklı, pnömoni ve tüberküloz sınıfları için sırasıyla %90, %99 ve %93 AUC skorları elde edilmiştir.

Patel vd. (2021)'nin yürüttüğü araştırma, göğüs röntgeni görüntülerini kullanarak pnömoni vakalarını tespit etmek amacıyla üç farklı önceden eğitilmiş evrişimli sinir ağlarının performanslarını karşılaştırmaktadır. Bu çalışmada önceden doğal görüntülerden oluşan geniş bir veri seti üzerinde eğitilmiş olan VGG16, VGG19 ve ResNet50 modellerini kullanan araştırmacılar, bu ESA modellerini pnömoni tespitine uygun hale getirmişlerdir. Modellerin performansını değerlendirmek için 5860 göğüs röntgeni görüntüsünden oluşan bir veri seti kullanılmış ve bu çalışmanın sonuçlarına göre, VGG16 modeli en iyi performansı göstermiştir. Bu model, 0,09'luk en düşük kayıp oranı ve %96.7'lik en yüksek doğruluk oranına ulaşmıştır. VGG19 ve ResNet50 modelleri ise sırasıyla %95.6 ve %88.14 doğruluk oranları ile 0.12 ve 0.29'luk kayıp oranları elde etmiştir.

Araştırmacılar, bu bulgular ışığında öğrenim aktarımının göğüs röntgeni görüntülerinden pnömoni tespiti için etkili ve verimli bir yöntem olduğu sonucuna varmışlardır. Bu çalışmanın, tıp uzmanlarına yardımcı olabileceğini ve potansiyel olarak birçok hayatı kurtarabileceğini öne sürmektedirler. Ayrıca, gelecekteki çalışmalar için model performansını ve genelleme yeteneğini artıracak bazı öneriler de sunmuşlardır. Dolayısıyla bu araştırma, makine öğrenimi tekniklerinin tıbbi görüntü analizindeki potansiyelini göstermesi açısından önemli bir adım olarak değerlendirilebilir.

Venkataramana vd. (2022)'nin çalışması göğüs röntgeni görüntülerini kullanarak çeşitli akciğer hastalıklarını teşhis etmek için derin öğrenme tekniklerinden yararlanan yenilikçi bir yaklaşım sunmaktadır. Bu araştırmanın temel amacı, tüberküloz, pnömoni ve COVID-19 gibi yaygın ve ciddi solunum yolu enfeksiyonlarının teşhisinde doğruluğu artırmaktır. Araştırmacılar, çok seviyeli bir sınıflandırma modeli önermektedir. Bu model, ilk aşamada tüberküloz ve pnömoniyi birbirinden ayırt etmekte, ardından pnömoniyi bakteriyel, viral ve COVID-19 türlerine göre sınıflandırmaktadır. Bu yaklaşım, farklı hastalıkların ayrımını daha hassas bir şekilde yapabilme potansiyeli de taşımaktadır. Çalışmada, veri setlerindeki sınıf dengesizliği sorunu da ele alınmıştır. Bu sorunun üstesinden gelmek için, azınlık sınıflarına ait örneklerin sayısını artırmak amacıyla veri artırma teknikleri kullanılmıştır. Bu yöntem, modelin tüm hastalık türlerini eşit şekilde öğrenmesini sağlamayı amaçlamaktadır. Araştırmada, sınıflandırma işlemi için evrişimsel sinir ağlarını tercih edilmiş olup ayrıca, özellik seçimi amacıyla

otokodlayıcı da kullanılmıştır. Bu kombinasyon, göğüs röntgeni görüntülerinden daha etkili bir şekilde bilgi çıkarılmasını ve hastalıkların daha doğru bir şekilde sınıflandırılmasını sağlamayı hedeflemektedir.

Yapay zekâ teknolojileri, tıp alanında, özellikle de histopatoloji görüntülerinin analizinde devrim niteliğinde gelişmelere yol açmıştır (Shmatko vd., 2022). Shmatko vd. (2022)'nin çalışması, bu teknolojilerin dijital histopatoloji alanındaki potansiyelini vurgulamaktadır. YZ yöntemleri, dijital histopatoloji görüntülerinden nicel bilgi çıkarma kapasitemizi önemli ölçüde artırmıştır.

2.2. Yapay Zeka

Yapay Zeka, öğrenme, problem çözme, karar verme ve algılama gibi genellikle insan zekası gerektiren görevleri yerine getirebilen bilgisayar sistemlerinin geliştirilmesini ifade etmektedir. YZ sistemleri, genellikle minimal insan müdahalesiyle tahminler yapmak, nesneleri sınıflandırmak için algoritmalar ve veri kullanır. YZ'nin nihai amacı, deneyimlerden öğrenebilen, yeni durumlara uyum sağlayabilen ve zaman içinde performanslarını iyileştirebilen, insan gibi düşünebilen ve hareket edebilen makineler yaratmaktır.

YZ'nin tarihi 1950'lere dayanmaktadır. Alan Turing, Marvin Minsky ve John McCarthy gibi bilgisayar bilimcileri, insan gibi düşünüp öğrenebilen makineler yaratma fikrini araştırmaya başladılar. “Yapay Zeka” terimi, 1956'da Dartmouth College'da ilk YZ konferansını düzenleyen McCarthy tarafından ortaya atıldı. 1960'lar ve 1970'lerde YZ araştırmaları, insanın karar verme süreçlerini taklit etmek üzere tasarlanmış kural tabanlı sistemler ve uzman sistemler geliştirmeye odaklandı. Ancak, bu erken YZ sistemleri esneklik eksikliği ve deneyimden öğrenme yeteneksizliği nedeniyle sınırlıydı. YZ'nin önemli ilerleme kaydetmesi, makine öğrenimi ve sinir ağlarının ortaya çıkmasıyla 1980'ler ve 1990'lara kadar gerçekleşmedi.

Bugün YZ, çeşitli dalları kapsayan geniş bir alandır. Bunlar arasında: Tahminler yapmak ve nesneleri sınıflandırmak için algoritmaların veri üzerinde eğitilmesini içeren makine öğrenimi; karmaşık verileri analiz etmek için sinir ağlarını kullanan MÖ'nün bir alt kümesi olan Derin Öğrenme (DÖ); (3) İnsan dilini anlayabilen ve üretebilen algoritmalar geliştirmeye odaklanan Doğal Dil İşleme (DDİ); (4) Görüntü ve videolardan görsel verileri yorumlayabilen ve anlayabilen algoritmalar geliştirmeyi içeren Bilgisayarlı Görü; (5) Çevreleriyle etkileşime girebilen ve uyum sağlayabilen akıllı makineler geliştirmeyi içeren Robotik; ve (6) Belirli alanlarda insan karar verme süreçlerini taklit

etmek üzere tasarlanmış Uzman Sistemler bulunur. YZ'nin bu farklı dallarının her biri, belirli görevlerde ve uygulamalarda önemli bir rol oynar. Örneğin, makine öğrenmesi ve derin öğrenme, birçok YZ uygulamasının temelini oluşturur. Bu ilişkiler ve yapay zekanın çeşitli bileşenleri Şekil 2.1'de görsel olarak özetlenmiştir.




Şekil 2.1. Yapay zeka ve alt dalları

2.3. Makine Öğrenmesi

Yapay zekanın bir alt kümesi olan makine öğrenmesi; tahminler yapmak, nesneleri sınıflandırmak gibi görevleri yerine getirmek için geniş bir şekilde kullanım alanına sahiptir. Makine öğreniminin amacı, bilgisayarların deneyimlerden öğrenmelerini ve zaman içinde performanslarını iyileştirmelerini sağlamaktır, bu da açıkça programlanmadan gerçekleşir. Makine öğrenimi algoritmaları, verileri analiz etmek, kalıpları tanımlamak ve kararlar vermek için istatistiksel teknikler kullanır. Bu algoritmalar, görüntü ve konuşma tanıma, doğal dil işleme ve geleceğe yönelik tahminler yapma gibi çok çeşitli görevlere uygulanabilir.

Makine öğrenmesi Şekil 2.2'de gösterildiği üzere, denetimli öğrenme, yarı denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme dahil olmak üzere dört ana grupta incelenebilir. Denetimli öğrenme, bir algoritmanın doğru çıktının zaten bilindiği etiketli veriler üzerinde eğitilmesini içerir. Algoritma, bu etiketli verilere dayanarak girdileri çıktılara eşlemeyi öğrenir ve daha sonra yeni, görülmemiş veriler üzerinde tahminler yapabilir. Öte yandan, yarı denetimli öğrenme hem etiketli hem de etiketlenmemiş veri kümelerini kullanarak modellerin eğitilmesini içerir. Bu yöntem, genellikle etiketli verilerin sınırlı olduğu durumlarda daha etkili sonuçlar elde etmek için

kullanılır. Etiketli veri setinden öğrenilen bilgi ve yapıları etiketlenmemiş veriler üzerinde uygulayarak modelin genel performansını iyileştirmeye çalışır. Denetimsiz öğrenme ise, bir algoritmanın etiketlenmemiş veriler üzerinde eğitilmesini içerir; burada algoritma, verilerdeki kalıpları ve yapıyı kendi başına bulmalıdır. Pekiştirmeli öğrenme, bir algoritmanın deneme yanılma yoluyla eğitilmesini içerir; burada algoritma, eylemlerine karşılık ödül veya ceza şeklinde geri bildirim alır.



Şekil 2.2. Makine öğrenmesi türleri

Makine öğreniminin görüntü ve konuşma tanıma, doğal dil işleme, öngörücü analitik ve öneri sistemleri dahil olmak üzere çok çeşitli uygulamaları vardır. Sağlık, finans, pazarlama ve ulaşım dahil olmak üzere birçok sektörde kullanılmaktadır. Makine öğrenimi, birçok görevi otomatikleştirme, verimliliği artırma ve işletmelerin daha iyi kararlar almasını sağlama potansiyeline sahiptir.

Bazı yaygın makine öğrenimi algoritmaları arasında karar ağaçları, lojistik regresyon, rastgele ormanlar, destek vektör makineleri sayılabilir. Bu çalışmada kullanılan makine öğrenmesi algoritmaları sonraki bölümlerde detaylandırılmıştır.


2.4. Derin Öğrenme

Derin öğrenme, makine öğreniminin bir alt kümesi olup, insan beynindeki karmaşık bilgi işleme sürecini taklit eden, çok katmanlı yapay sinir ağlarını kullanarak verilerden öğrenme ve çıkarım yapma yöntemidir. Bir sinir ağı, girdi olarak verilen veri ile çıktı olarak istenen veri arasında bağlantıyı sağlayan nöronlardan meydana gelmektedir. Girdi ve çıktılar arasındaki nöron katmanlarına gizli katmanlar denmekle beraber, gizli katman sayısının yirmiden fazla olması durumunda “derin” sinir ağları ifadesi kullanılır. Derin sinir ağları birkaç katman olabileceği gibi, binlerce katmandan da meydana gelebilmektedir. Basit bir sinir ağı katmanları Şekil 2.3’te tasvir edilmiştir. Bu ağlar, görüntüler, konuşma ve metin gibi verilerdeki karmaşık kalıpları öğrenmek için tasarlanmıştır. Derin öğrenme algoritmaları, görüntü tanıma, konuşma tanıma ve doğal

dil işleme dahil olmak üzere çok çeşitli görevlerde son derece iyi bir performans elde etmek için kullanılmaktadır.

Her bir katmandaki nöronlar, aldıkları girdiyi bir takım matematiksel işlemlerden geçirir. Bu işlemler, girdinin ağırlık (w) ile çarpılması, sapma değişkeni (b) ile toplanması ve ardından aktivasyon fonksiyonundan geçirilmesi şeklindedir. Elde edilen sonuç, bir sonraki katmandaki nörona aktarılır. Bu işlem, son çıkış (output) nöronuna kadar katmanlar arasında devam eder. Bu sürece ileri doğru yayılım (forward propagation) adı verilmektedir. Son nöron katmanında ise artık nihai sonuç üretilir. Oluşturulan yapı eğitim boyunca sürekli olarak hata hesabı yapar ve hatayı minimize etmeye çalışır. Üretilen sonuç, gerçek değerden farklı ise öğrenmenin yeterli seviyede olmadığı sonucuna varılır. Bu durumda, ağıda geriye doğru gidilerek ağırlık ve sapma değişkenleri yeniden düzenlenir. Bu işlem, hata minimize edilene kadar devam eder. Parametrelerin bu şekilde optimize edilmesi geri yayılım (back propagation) olarak adlandırılır.

Bazı yaygın derin öğrenme algoritmaları arasında evrişimli sinir ağları, tekrarlayan sinir ağları (RNN) ve uzun kısa süreli bellek (LSTM) ağları bulunur. ESA'lar, görüntüler gibi ızgara benzeri topolojiye sahip verileri işlemek için tasarlanmıştır. RNN'ler, konuşma veya metin gibi sıralı verileri işlemek için tasarlanmıştır. LSTM ağları, verilerdeki uzun vadeli bağımlılıkları ele almak için tasarlanmış bir RNN türüdür.



Şekil 2.3. Basit bir yapay sinir ağı gösterimi.

2.5. Performans Metrikleri

Makine öğrenimi veya derin öğrenme gibi modellerin etkinliğini değerlendirmek için bir takım performans metriklerinden faydalanılır. Bu metrikler, eğitilen modellerin ne kadar iyi bir performans sergilediğini karşılaştırmak için kullanılır. Sınıflandırma ve regresyon problemleri için bu metrikler farklılık göstermekle beraber, sınıflandırma için

yaygın olan kullanılan metrikler; doğruluk (accuracy), duyarlılık (recall), kesinlik (precision), F1 skoru ve Area Under Curve (AUC) olarak adlandırılan ROC eğrisinin altında kalan alanın değeridir. Regresyon problemleri için ise Ortalama Kare Hata (Mean Squared Error, MSE), ortalama Mutlak Hata (Mean Absolute Error, MAE) ve R-Kare (R-Squared) kullanılır.

Sınıflandırma problemlerinde modellerin performanslarını hesaplamak için Karışıklık matrisi (Confusion Matrix) önemli bir araçtır. Bu matris, modelin tahminlerini gerçek değerlerle karşılaştırarak dört temel kategori sunar: Doğru pozitif (True Positive, TP), Doğru Negatif (True Negative, TN), Yanlış Pozitif (False Positive, FP) ve Yanlış Negatif (False Negative, FN). Bu değerler, yukarıda bahsedilen performans metriklerinin hesaplanmasında kullanılır.

Bu çalışma bir sınıflandırma ve nesne tespiti (lokalizasyon) problemini konu eddiğinden, bu çalışmada faydalanan sınıflandırma performans metrikleri Denklem 2.1, 2.2, 2.3 ve 2.4'teki gibi tanımlanmışlardır.

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \quad (2.1)$$

$$\text{Kesinlik} = \frac{TP}{TP+FP} \quad (2.2)$$


$$\text{Duyarlılık} = \frac{TP}{TP+FN} \quad (2.3)$$

$$\text{F1 Skoru} = 2 \times \frac{\text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (2.4)$$

Lokalizasyon probleminin performans değerlendirmesinde ise kesinlik, duyarlılık ve mAP50 ve güven skoru metriklerinden faydalanılmıştır. Bu metriklerden mAP50 (Mean Average Precision at 50% IoU), nesne tespiti görevlerinde yaygın olarak kullanılan bir metriktir. mAP50, modelin tüm sınıflar üzerindeki genel performansını tek bir sayı ile ifade eder. mAP50'deki "50", tahmin edilen sınırlayıcı kutu ile gerçek sınırlayıcı kutu arasındaki örtüşmenin (Kesişim Birleşim Oranı, KBO) en az %50 olması gerektiğini belirtir; KBO ise, iki sınır kutusu arasındaki örtüşme alanının (Şekil 2.4 (a)), birleşim alanına (Şekil 2.4 (b)) bölünmesiyle hesaplanır (Denklem 2.5). Bu metrik, modelin nesneleri bulma (duyarlılık) ve yanlış pozitifleri önleme (hassasiyet) yeteneğini dengeli bir şekilde değerlendirir. Yani, mAP'nin bu özel versiyonu, tahmin edilen sınır kutusunun, gerçek sınır kutusuyla en az %50 örtüşme sağladığında doğru pozitif olarak kabul

edildiğinde ortalama doğruluğu hesaplar. mAP50, 0 ile 1 arasında değer alır ve daha yüksek bir değer, daha iyi bir genel performansı gösterir.

$$KBO(IoU) = \frac{\text{Örtüşme Alanı}}{\text{Birleşim Alanı}} \quad (2.5)$$



Şekil 2.4. a) Etiketlenmiş bölge ile tahmin edilen bölgelerin birleşim ve b) kesişim alanları

Güven skoru ise bir nesnenin yüzde kaç olasılıkla o nesne olduğunu belirten bir metriktir ve Denklem 2.6'daki gibi hesaplanır.

$$\text{Güven Skoru} = P(\text{nesne}) \times KBO \quad (2.6)$$

Burada $P(\text{nesne})$ ızgara içinde nesnenin bulunma olasılığıdır.

3. MATERYAL VE YÖNTEM

3.1. Materyal


Çalışmada incelenen tüberküloz lezyonlarına sahip akciğer örnekleri, tüberküloz pozitif hayvanların zorunlu kesime tabi tutulduğu bir mezbahadan (Suhut, Afyonkarahisar, Türkiye) ve Patoloji Anabilim Dalı arşivlerinden elde edilmiştir. Pnömoni vakalarına ait akciğer görüntüleri ise mevcut arşiv preparatlarından sağlanmıştır. Tüberkülozun yasal olarak bildirilmesi zorunlu bir hastalık olması sebebiyle, araştırma materyallerinin toplanması için gerekli izinler alınmıştır. Bu kapsamda, çalışmanın etik uygunluğu Burdur Mehmet Akif Ersoy Üniversitesi/Türkiye Yerel Hayvan Deneyleri Etik Kurulu tarafından onaylanmıştır (MAKU HADYEK /1177, tarih 28.08.2023).

3.1.1. Veri Seti

Bu çalışmada kullanılan veri seti, sığır akciğer örneklerinden elde edilen mikroskopik görüntülerden oluşmakta olup, Türkiye Cumhuriyeti Tarım ve Orman Bakanlığı'nın verdiği yasal izne uygun olarak kullanılmıştır. Bu araştırmanın temel amaçlarından biri, akciğer kesitlerinde pnömoni ve tüberküloz gibi patolojik durumların ayrımını hedefleyen ikili sınıflandırma yapmaktır.

Veri seti, mezbahadan ve arşiv materyallerinden elde edilen örneklerden oluşmaktadır. Mezbahadan alınan örnekler, çoğunluğu Holstein ineklere ait olan ve Burdur, Isparta ve Afyon bölgelerinden gelen hayvanlardan toplanmıştır. Toplamda, arşivden alınanlarla birlikte 13 tipik tüberküloz vakasından örnekler alınmıştır. Arşiv materyallerinden ayrıca, pnömoni vakalarından tipik bulguları olan 10 hayvandan fotoğraflar çekilmiştir.

Tüberküloz ve pnömoni sınıfları sırasıyla 247 ve 256 görüntü örneğinden oluşmakta ve her iki sınıftaki tüm görüntüler, 3840 x 2027 piksel çözünürlüğe sahiptir. Şekil 3.1'de bu çalışmada kullanılan tüberküloz, pnömoni ve sağlıklı doku örnekleri sırasıyla gösterilmiştir. Bu çalışmada sağlıklı doku örnekleri kullanılmamıştır. Ancak, diğer iki sınıf ile karşılaştırma yapabilmek amacıyla sağlıklı doku görüntüsü de Şekil 3.1'de gösterilmiştir.



Şekil 3.1. Sırasıyla tüberküloz, pnömoni ve sağlıklı doku örnekleri

3.1.2. Yazılımlar ve Araçlar

Bu tez çalışmasında kullanılan yazılım ve araçlar şunlardır:

- Database Manual CellSens Life Science Imaging Software System (Olympus Corporation, Tokyo, Japonya): Mikroskopik görüntülerin kaydedilmesi için kullanılmıştır.
- Python Programlama Dili ve Kütüphaneler: TensorFlow, Keras, Scikit-learn, gibi kütüphaneler kullanılmıştır.
- Görüntü İşleme ve Makine Öğrenimi Modelleri: YOLOv8, ResNet-50, Lojistik Regresyon, Destek Vektör Makineleri, Rastgele Orman ve Naïve Bayes algoritmaları kullanılmıştır.

3.1.3. Donanım

Görüntülerin etiketlenmesi, Windows 10 işletim sistemine sahip, Intel i5-8250U işlemcili, NVIDIA GeForce 940MX ekran kartlı ve 32 GB RAM bulunan bir bilgisayarda gerçekleştirilmiştir. Etiketleme işlemi için LabelImg (HumanSignal, 2024) programı kullanılmıştır. Görüntü artırma (image augmentation) ve model geliştirme süreçleri ise Kaggle.com platformunda gerçekleştirilmiştir.

3.2. Histopatoloji Yöntemi

Endemik bölgelerdeki bTB kontrol programlarının önemli bir bileşeni, tüberkülin testi reaktörlerinde veya düzenli olarak kesilen hayvanlarda enfeksiyonu tespit eden postmortem analizdir (Pascual-Linaza vd., 2017). Sığır tüberkülozunun belirgin özelliği, tüberkül olarak bilinen granülomatöz nodüllerin gelişimidir. Bunlar, 2 ila 20 mm çapında, sınırlı sarımsı enflamatuvar nodüller olup, bağ dokusu tarafından kapsüllenmiş ve sıklıkla merkezi kazeöz nekroz ve mineralizasyon içermektedir (Ozmen vd., 2005; Ozmen, 2009;

Domingo vd., 2014; Sevtekin ve Ozmen, 2018). Bu çalışmada, mezbaha materyallerinde karakteristik tüberküller teşhis edilmiş ve bu lezyonlardan örnekleme yapılmıştır.

Sevtekin ve Ozmen (2018) çalışmalarında, mikroskopik sınıflandırmaya göre dört evreye (evre I, II, III ve IV) ayrılan tüberküloz lezyonlarının ayırt edici histolojik görüntüleri tanımlanmışlardır. Evre I: Burada dağınık lenfositler, düzensiz epitelooid makrofajlar ve Langhans tipi birkaç çok çekirdekli dev hücreler bulunur. Evre II granülomlarda nötrofiller, lenfositler ve makrofajların yanı sıra az sayıda fibroblast ve Langhans tipi hücre ile birlikte sınırlı nekroz görülmüştür. Evre III granülomları, merkezi kazeöz nekrozun çevresinde Langhans tipi büyük hücreler ve epitelooid hücreler ile birlikte merkezi kalsifikasyon göstermiştir. Fibröz kapsülün yakınındaki enflamatuvar hücre popülasyonu, lenfositler, her tarafa yayılmış nötrofiller ve makrofajlardan oluşmaktaydı. Evre IV granülomların çoğunda mineralizasyon ve nekroz görülmüştür. Kalın kapsüllü lezyonlar daha az yayılmanın ve *M. bovis*'e karşı güçlü bir bağışıklık tepkisinin göstergesidir (Canal vd., 2017). Spesifik olmamakla birlikte, Langhans dev hücreleri bTB tanısı için karakteristik olarak kabul edilmektedir (Ozmen vd., 2005; Ozmen, 2009; Canal vd., 2017; Sevtekin ve Ozmen, 2018; Borham vd., 2022).

Bu tez çalışmasında, mezbahadan elde edilen örnekler %10 formalin çözeltisinde sabitlenmiş, standart işlemlerden geçirilmiş ve parafine gömülmüştür. Gerek arşivdeki, gerekse yeni hazırlanan tüberküloz ve pnömoni örneklerinden 5 mikron kalınlığında kesitler alınmış ve daha sonra bu kesitler Hematoksilin-Eozin (HE) ile boyanmıştır. Pnömoni vakalarının ve karakteristik tüberkül oluşumlarının mikroskopik görüntüleri, Database Manual CellSens Life Science Imaging Software System (Olympus Corporation, Tokyo, Japonya) kullanılarak kaydedilmiştir.

3.3. Makine Öğrenmesi Yöntemleri

3.3.1. Lojistik Regresyon


Lojistik regresyon, makine öğrenimi tarafından ödünç alınan istatistiksel bir araç olup, sınıflandırma görevleri için temel bir algoritmadır. Bu yöntem, bir örneğin belirli bir sınıfa ait olma olasılığını analiz ederek karar verme sürecine yardımcı olur. Doğrusal regresyonun aksine, lojistik regresyon aykırı değerlerden daha az etkilenir ve Denklem 3.1'de gösterilen sigmoid fonksiyonunu kullanır. Sigmoid fonksiyonu, doğrusal regresyondaki en uygun çizgiyi S şeklinde bir eğriye dönüştürerek 0 ile 1 arasında bir değer döndürür.

$$\sigma(z) = \frac{1}{1 + e^{-z}} \quad (3.1)$$

Burada z , ‘logit’ olarak adlandırılır ve giriş özelliklerinin (x_i) ilgili ağırlıklarla (b_i) doğrusal bir kombinasyonudur. Bu ilişki Denklem 3.2’de gösterilmektedir.

$$z = b_0 + b_1x_1 + b_2x_2 + \dots + b_nx_n \quad (3.2)$$

Sigmoid fonksiyonunun S şeklindeki eğrisi, lojistik regresyonun temelini oluşturur. Şekil 3.2 sigmoid fonksiyonunun bu karakteristik S şeklindeki eğrisini göstermektedir. Bu grafik, lojistik regresyonun çalışma prensibini ve verileri nasıl sınıflandırdığını daha iyi anlamaya olanak sağlar.




Şekil 3.2. Lojistik regresyonun olasılık eğrisi

Lojistik regresyon, özellikle ikili sınıflandırma problemlerinde yaygın olarak kullanılır. Örneğin, bir e-postanın spam olup olmadığını belirlemek, bir müşterinin bir ürünü satın alıp almayacağını tahmin etmek veya bir hastanın belirli bir hastalığa sahip olup olmadığını tespit etmek gibi durumlarda etkili bir şekilde uygulanabilir.


3.3.2. Destek Vektör Makineleri (DVM)

Destek vektör makineleri (Cortes ve Vapnik, 1995), tarafından geliştirilen bir makine öğrenmesi algoritması türüdür. Bu algoritma, sınıflandırma, regresyon, aykırı değer tespiti gibi görevleri gerçekleştirebilme yeteneğine sahiptir. DVM, görüntü sınıflandırma, spam tespiti, anomali tespiti, gürültü sınıflandırma ve parçacık fiziğinde sinyal/ardalan sınıflandırması gibi çeşitli alanlarda yaygın olarak uygulanmaktadır.

İkili sınıflandırma senaryolarında DVM, veri noktalarını farklı sınıflara ayıran optimal bir hiperdüzlem bulmaya çalışır. Bu hiperdüzlem, iki boyutlu uzayda bir doğru, üç boyutlu uzayda ise bir düzlem olarak, daha yüksek “ n ” boyutlu uzaylarda ise, “ $n-1$ ” boyutlu hiper düzlem olarak düşünülebilir. Şekil 3.3, DVM'nin üç boyutlu uzayda nasıl çalıştığını gösterirken, Şekil 3.4 ise iki boyutlu bir uzayda DVM'nin işleyişini açıklamaktadır. Her iki durumda da DVM farklı sınıflara ait veri noktalarını en iyi şekilde ayıran optimal bir hiperdüzlem bulmaya çalışır. Üç boyutlu uzayda bu hiperdüzlem bir düzlem olarak görünürken, iki boyutlu uzayda bir doğru halini alır. Şekil 3.4’de görülen siyah çizgi, hiperdüzlemi temsil eder ve iki farklı sınıfa ait veri noktalarını (açık mavi ve koyu kahverengi noktalar) en iyi şekilde ayırır. DVM'nin gücü, bu hiperdüzlemi belirlerken marjini maksimize etmesinden kaynaklanır. Marjin, hiperdüzlem ile en yakın veri noktaları arasındaki mesafedir ve kesikli çizgilerle gösterilmiştir. Marjinin sınırlarında yer alan noktalar, destek vektörleri olarak adlandırılır ve hiperdüzlem konumunu belirlemede kritik öneme sahiptir.



Şekil 3.3. Üç boyutlu uzayda ikili sınıflandırma ve ayırıcı hiperdüzlem



Şekil 3.4. DVM'in İki boyutlu uzayda sınıflandırma mekanizması: Hiperdüzlem, marjın ve destek vektörleri

Marjının genişliği ve destek vektörlerinin sayısı, modelin esnekliğini ve genelleme yeteneğini etkiler. Bu noktada, modelin karmaşıklığını ve doğruluğunu dengelemeye yardımcı olan C parametresi devreye girer. C parametresi, DVM modelinde önemli bir hiperparametredir ve modelin marjın ihlallerine ne kadar tolerans göstereceğini belirler. Yüksek bir C değeri, daha az marjın ihlaliyle sonuçlanır ve model verileri daha sıkı bir şekilde ayırmaya çalışır. Bu durumda, modelin doğruluğu artabilir, ancak genelleme yeteneği azalabilir. Öte yandan, düşük bir C değeri, daha geniş bir marjın ve daha fazla marjın ihlali anlamına gelir, bu da modelin genelleme yeteneğini artırabilir ancak doğruluğunu azaltabilir.

DVM, yalnızca doğrusal problemlerle sınırlı değildir; polinom ve sigmoid gibi çekirdek fonksiyonları kullanarak doğrusal olmayan problemlerde de gayet başarılıdır. Bu çekirdek fonksiyonlar, veri noktalarını daha yüksek boyutlu bir özellik uzayına dönüştürerek, bu uzayda doğrusal olarak ayrılabilir veya regresyon yapılabilir hale getirir. DVM'lerin güçlü yönleri arasında yüksek boyutlu uzaylarda etkili çalışabilmesi, farklı çekirdek fonksiyonları kullanılarak esneklik sağlama ve aşırı öğrenme (overfitting) riskinin nispeten düşük olması sayılabilir. Bununla birlikte, büyük veri setlerinde hesaplama maliyetinin yüksek olması ve optimal parametrelerin belirlenmesinin zor olabilmesi gibi dezavantajları da vardır.

3.3.3. Rastgele Orman

Rastgele Orman hem sınıflandırma hem de regresyon problemlerinde kullanılabilen bir denetimli öğrenme algoritmasıdır. Bu algoritma, topluluk öğrenmesi (ensemble learning) yöntemlerinden biridir ve bir dizi karar ağacından oluşur.


N özellikli M tane veri noktasından olduğunu farz edersek, bu veri setini $X = \{x_1, x_2, \dots, x_m\}$ şeklinde gösterebiliriz, burada her x_i , N boyutlu bir vektördür: $x_i = (x_{i1}, x_{i2}, \dots, x_{in})$. Bu veri seti, bir $M \times N$ boyutlu matris olarak da düşünülebilir. Bu algoritmanın temelinde, veri setinden rastgele örnekleme (bootstrap) yöntemiyle oluşturulan farklı alt kümeler yatar. Her bir karar ağacı, bu alt kümelerden biri kullanılarak eğitilir. Ağaçları oluştururken, algoritma ayrıca her düğümde kullanılacak özellikleri de rastgele seçer. Böylece, her ağaç hem farklı veri örnekleri hem de farklı özellik alt kümeleri kullanılarak eğitilmiş olur. Örneğin, k tane alt küme oluşturduğumuzu ve her alt kümenin L tane veri noktası içerdiğini varsayalım. Bu alt kümeleri $(S_j = \{s_1, s_2, \dots, s_L\} (j = 1, 2, \dots, k))$ şeklinde gösterebiliriz. Ayrıca, her alt küme için t tane rastgele özellik seçildiğini düşünürsek, bu özellikleri de $F_j = \{f_1, f_2, \dots, f_t\}$ olarak ifade edebiliriz. Her bir alt küme (S_j) ve seçilen özellikler (F_j) kullanılarak (k) tane karar ağacı (T_j) oluşturulur. Bu karar ağaçları matematiksel olarak $T_j = f(S_j, F_j)$ şeklinde gösterilebilir, burada f karar ağacı oluşturma fonksiyonudur. Rastgele orman algoritmasının işleyiş yapısı ikili sınıflandırma örneği için Şekil 3.5'te verilmiştir. Burada her bir karar ağacı S_j alt küme veri seti ve F_j özellikleri kullanılarak bağımsız olarak eğitilir ve her biri kendi tahminini üretir. Bu tahminler çoğunluk oylaması ile birleştirilerek nihai sonuç elde edilir.

Model, yeni bir veri noktası için tahmin yaparkende, yine tüm ağaçların tahminlerini birleştirir; sınıflandırma problemlerinde çoğunluk oylaması, regresyon problemlerinde ise ortalama alınır. Matematiksel olarak, yeni bir veri noktası x için bu tahminler şu şekilde ifade edilebilir:

$$\text{Sınıflandırma için: } y = \text{mode}(T_1(x), T_2(x), \dots, T_k(x))$$

$$\text{Regresyon için: } y = \frac{1}{k} \sum_{j=1}^k T_j(x)$$

Bu yöntem, modelin genelleme yeteneğini artırır ve aşırı uyum riskini azaltır. Rastgele orman algoritmasının önemi, yüksek doğruluk, esneklik ve dayanıklılık sağlamasından kaynaklanır. Birden fazla karar ağacının bir araya gelmesi, modelin tek bir ağacın hatalarına karşı daha az duyarlı olmasını sağlar. Ayrıca, veri setindeki gürültü ve aykırı değerlerin etkisini azaltır. Rastgele orman, büyük veri setlerinde ve yüksek boyutlu özellik uzaylarında etkili bir şekilde çalışabilir ve önemli özelliklerin seçilmesine yardımcı olur. Bu özellikler, algoritmayı birçok uygulama alanında, özellikle biyoinformatik, finans ve pazarlama gibi alanlarda popüler ve değerli bir araç haline getirmiştir.



Şekil 3.5. Rastgele orman algoritmasının sınıflandırma görevi için çalışma mekanizması

3.3.4. Naive Bayes

Naive Bayes algoritması, gözlemlenen olayın olasılığı verildiğinde bir olayın olasılığını hesaplayan Bayes teoremine (Denklem 3.3) dayanan olasılıksal bir sınıflandırma tekniğidir. Bu sınıflandırıcı, her bir özelliğin aynı ağırlığa sahip olduğunu ve sınıf verildiğinde her bir özellik çiftinin birbirinden bağımsız olduğunu varsayar. Bu basitleştirici varsayıma rağmen, Naive Bayes, çeşitli gerçek dünya uygulamalarında dikkate değer bir etkinlik göstermiştir. Algoritma, özellikle metin sınıflandırma, spam filtreleme ve doğal dil işleme gibi görevler için çok uygundur.

$$P(A | B) = \frac{P(B | A)P(A)}{P(B)} \quad (3.3)$$

Temsil edilen hedef değişkenin 'y' ve özellik vektörünün $X = (x_1, x_2, \dots, x_n)$ olarak tanımlandığı durumda, Bayes teoremi veri setine aşağıdaki şekilde uygulanabilir:

$$P(y | X) = \frac{P(X | y)P(y)}{P(X)} \quad (3.4)$$

Naive varsayım altında, yani özelliklerin birbirinden bağımsız olduğu varsayıldığında, Denklem 3.4'ü A ve B'nin bağımsız olma özelliğini kullanarak aşağıdaki şekilde yeniden yazabiliriz:

$$P(y | x_1, \dots, x_n) = \frac{P(x_1 | y)P(x_2 | y) \dots P(x_n | y)P(y)}{P(x_1)P(x_2) \dots P(x_n)} \quad (3.5)$$

Bu durumda, Denklem 3.5 aşağıdaki gibi kompakt formda yazılabilir:

$$P(y | x_1, \dots, x_n) = \frac{P(y) \prod_{i=1}^n P(x_i | y)}{P(x_1)P(x_2) \dots P(x_n)} \quad (3.6)$$

Denklem 3.6'da payda kısmı sabit olduğu için göz ardı edilebilir ve verilen özellikler kümesi için 'y' sınıfının maksimum olasılığı şu şekilde elde edilebilir:

$$y = \underset{y}{\operatorname{argmax}} P(y) \prod_{i=1}^n P(x_i | y) \quad (3.7)$$


3.4. Derin Öğrenme Yöntemleri

3.4.1. Evrişimli Sinir Ağları

Evrişimli sinir ağları, görüntü işleme ve bilgisayarlı görü alanında çığır açan bir derin öğrenme mimarisidir. ESA'lar, özellikle görsel verilerin hiyerarşik özelliklerini otomatik olarak çıkarma ve öğrenme konusunda üstün performans gösterir. Bu ağlar, insan görme sisteminin çalışma prensiplerinden esinlenerek tasarlanmıştır ve görüntülerdeki uzamsal ilişkileri etkili bir şekilde yakalayabilir.

Şekil 3.6'da temel bir ESA mimarisi gösterilmiştir. Bu mimaride tipik olarak bir giriş katmanı, bir veya daha fazla evrişim (convolution) katmanı, aktivasyon katmanları, havuzlama, düzleştirme, tam bağlantı ve sınıflandırıcı katmanlar yer almaktadır. Giriş katmanı, modele verilen görüntünün piksel değerlerini temsil eder. Giriş katmanı, genellikle görüntünün yüksekliği, genişliği ve renk kanallarının sayısını yansıtan üç boyutlu bir yapıya sahiptir. Bu görüntü, görüntüdeki önemli özellikleri tespit etmek için farklı filtreler kullanan evrişim katmanlarından geçirilir. Her evrişim katmanını bir havuzlama katmanı takip eder, bu katman özellik haritalarının boyutunu küçülterek


hesaplama yükünü azaltır ve modelin uzamsal değişimlere karşı dayanıklılığını artırır. Bu işlemler birkaç kez tekrarlanarak görüntünün daha soyut ve yüksek seviyeli özellikleri çıkarılır. Her evrişim katmanından sonra gradyanların kaybolmasının önüne geçmek adına ReLU (Rectified Linear Unit), Leaky ReLU veya sigmoid gibi aktivasyon fonksiyonları kullanılır. Bu aktivasyon fonksiyonlarından ReLU, negatif değerleri sıfıra eşitleyerek ve pozitif değerleri olduğu gibi geçirerek doğrusal olmayan bir yapı sağlar, bu da modelin karmaşık örüntüleri öğrenmesine yardımcı olur. Son olarak, elde edilen özellikler düzleştirme katmanı (Flattening) ile bir vektöre dönüştürülür ve tam bağlantılı katmanlar (Fully Connected Layer) aracılığıyla işlenerek nihai sınıflandırma sonucu elde edilir.



Şekil 3.6. Evrişimli sinir ağı mimarisi örneği


ESA'ların temel yapı taşı olan evrişim katmanları, görüntü üzerinde küçük filtreler (kernels) kaydırarak özellik haritaları oluşturur. Bu işlem, görüntünün farklı bölgelerindeki benzer özellikleri tespit etmeye yarar. Matematiksel olarak, evrişim işlemi, iki ayrı matrisin eleman bazında birbirleri ile çarpımının toplamıdır. Şekil 3.7'de gösterildiği gibi, görüntü işleme alanında bu işlem, bir filtrenin giriş görüntüsü üzerinde kaydırılması ve her konumda nokta çarpımı alınması şeklinde gerçekleştirilir. Filtre (genellikle 3x3 veya 5x5 boyutunda bir matris), giriş görüntüsü üzerinde soldan sağa ve yukarıdan aşağıya doğru kaydırılır. Her konumda, filtrenin kapsadığı giriş piksellerinin değerleri ile filtrenin ağırlıkları çarpılır ve sonuçlar toplanır. Bu toplam, çıkış özellik haritasında ilgili konuma yazılır. Elde edilen yeni görüntünün boyutu $(n - f + 1) \times (n - f + 1)$ olacaktır. Burada n , $n \times n$ boyutunda olan giriş görüntüsünden, f ise $f \times f$ olan filtre boyutundan gelmektedir. Görüntünün renkli olması durumunda ise, her bir renk kanalı için ayrı ayrı aynı boyutta filtreler kullanılır. Örneğin, RGB görüntüsü için $f \times f \times 3$ boyutunda bir filtre kullanılır. Bu filtre, görüntünün tüm kanalları üzerinde aynı anda gezdirilir ve bu evrişim işlemi sonunda tek bir sayı elde edilir. Bu sayı, çıkış özellik

haritasındaki ilgili konuma karşılık gelir. Ayrıca, modern ESA mimarilerinde genellikle birden fazla filtre kullanılır. Her filtre farklı bir özelliği öğrenmeye çalışır. Örneğin, k adet filtre kullanılıyorsa, evrişim işlemi sonucunda k adet $(n - f + 1) \times (n - f + 1)$ boyutunda özellik haritası elde edilir.



Şekil 3.7. 5×5 Renkli bir görüntü üzerine evrişim işleminin uygulanışı


Evrişim işlemi uygulandığında Şekil 3.7’den de görüldüğü üzere görüntünün boyutu küçülür. Bu işlemi tekrarladıkça, görüntü giderek daha da küçülür ve bilgi kaybına sebep olur. Diğer bir problem de, evrişim sırasında köşelerdeki ve kenarlardaki pikseller sadece bir kez değerlendirilir. Bu, evrişimin bir dezavantajıdır. Görüntünün ortasındaki bir pikseli düşünürsek, bu piksel birden fazla kez evrişim sırasında hesaba katılırken, ancak köşe ve kenarlardaki pikseller çok daha az kullanılır. Böylece, görüntünün kenarlarındaki önemli bilgilerin çoğu göz ardı edilmiş olur. Bu sorunu çözmek için ‘dolgu’ (padding) tekniği kullanılır. Dolgu, görüntünün etrafına ek pikseller ekleyerek hem boyut küçülmesini önler hem de kenar ve köşe piksellerinin de daha fazla değerlendirilmesini sağlar. Şekil 3.8’de dolgu değeri (p) ‘1’ olacak şekilde görüntüye dolgu yapıldığı görülmektedir. 4×4 olan görüntü 6×6 olmuş, daha sonra evrişim işlemi uygulanmıştır. Bu sayede, evrişim işlemi sırasında bilgi kaybını minimize ederiz ve ağız görüntünün tüm bölgelerini eşit şekilde değerlendirmesini sağlanır.



Şekil 3.8. Görüntü üzerine dolgu tekniğinin uygulanışı

İlk evrişimli katmanlar genellikle basit, düşük seviyeli özellikleri öğrenir. Bunlar kenarlar, köşeler, basit şekiller veya renk geçişleri gibi temel görsel elemanlardır. Daha sonraki evrişimli katmanlar ise bu basit özellikleri birleştirerek daha karmaşık, yüksek seviyeli özellikleri öğrenir. Örneğin, nesnelerin parçaları, dokular veya daha soyut desenler gibi özellikler. Evrişim işlemi, görüntünün uzamsal yapısını korurken, aynı zamanda parametre paylaşımı sayesinde ağıın toplam parametre sayısını azaltır. Bu özellik, ESA'ların büyük veri setleri üzerinde etkili bir şekilde eğitilmesini ve aşırı öğrenme riskini azaltmasını sağlar.

ESA'larda kullanılan ve genellikle evrişimli katmanlardan sonra eklenen havuzlama katmanları, özellik haritalarının boyutunu küçültmeye ve önemli özellikleri vurgulamaya yarar. Aynı zamanda ağıın eğitilmesi sırasında kullanılacak parametre sayısını azaltarak kullanılan hesaplama yükünü de düşürür. En yaygın havuzlama yöntemleri arasında maksimum havuzlama ve ortalama havuzlama bulunur. Maksimum havuzlama, her bir bölgedeki en yüksek değeri alırken, ortalama havuzlama bölgedeki değerlerin ortalamasını alır. Havuzlama işlemi görüntünün boyutlarını değiştirirken renk kanalı sayısına etki etmez ve ağıın küçük uzamsal değişimlere karşı daha dayanıklı olmasını sağlar. Şekil 3.9'da havuzlama metodunun adım uzunluğu (stride) soldan sağa yukarıdan aşağı 2 birim olması ve filtre boyutunun 2×2 olması durumunda, ortalama havuzlama ve maksimum havuzlama yöntemlerinin uygulanışı ve elde edilen özellik haritaları gösterilmiştir.



Şekil 3.9. Havuzlama metodunun uygulanışı

ESA'ların performansını artırmak için kullanılan tekniklerden biri de normalizasyon katmanlarıdır. Batch normalizasyonu, her bir mini-batch içindeki aktivasyonları normalize ederek ağıın daha hızlı ve kararlı bir şekilde eğitilmesini sağlar. Bu teknik, derin ESA'ların eğitiminde gradyan akışını iyileştirir ve daha yüksek öğrenme

oranları kullanılmasına olanak tanır. ESA'ların eğitiminde kullanılan optimizasyon algoritmalarının seçimi de önemlidir. Stokastik gradyan inişi (SGD), Adam, RMSprop gibi algoritmalar yaygın olarak kullanılır. Bu optimizasyon algoritmaları, ağırlık parametrelerini güncelleyerek kayıp fonksiyonunu minimize etmeye çalışır. Ayrıca, öğrenme oranı planlaması ve erken durdurma gibi teknikler de ESA'ların eğitim sürecini iyileştirmek için kullanılır.

ESA'ların öğrenim aktarımı kapasitesi de önemli bir avantajdır. Büyük veri setleri üzerinde önceden eğitilmiş ESA modelleri (örneğin, ImageNet üzerinde eğitilmiş VGG, ResNet, Inception gibi modeller), daha küçük ve özel veri setlerine uyarlanabilir. Bu yaklaşım, sınırlı veri ve hesaplama kaynağı olan durumlarda bile yüksek performanslı modeller elde etmeyi mümkün kılar.

Son yıllarda, ESA mimarileri üzerinde yapılan yenilikler, bu ağların performansını daha da artırmıştır. Örneğin, artık bağlantılar (residual connections) kullanan ResNet mimarisi, çok derin ağların eğitilmesini kolaylaştırmıştır. Inception modülleri, farklı boyutlardaki özellikleri eşzamanlı olarak çıkarmak için paralel evrişim katmanları kullanır. DenseNet mimarisi ise, her katmanı önceki tüm katmanlarla doğrudan bağlayarak özellik yeniden kullanımını ve gradyan akışını iyileştirir.

ESA'lar, görüntü sınıflandırma, nesne tespiti, semantik segmentasyon ve yüz tanıma gibi birçok görüntü işleme görevinde başarıyla uygulanmaktadır. Ayrıca, doğal dil işleme, zaman serisi analizi ve hatta ilaç keşfi gibi alanlarda da kullanımları giderek artmaktadır. ESA'ların çok yönlülüğü ve güçlü özellik çıkarma yetenekleri, onları yapay zeka ve makine öğrenmesi alanında vazgeçilmez bir araç haline getirmiştir.


3.4.2. Öğrenim Aktarımı (Transfer Learning)

Öğrenim aktarımı, makine öğrenmesinin temel bir bileşeni olarak, birçok alanda oyunun kurallarını değiştiren bir yöntem haline gelmiştir (Bişkin vd., 2023; Celik, 2023; 2024). Öğrenim aktarımının iki türü bulunmaktadır: ince ayar (fine-tuning) ve özellik çıkarımı (feature extraction). İnce ayar sürecinde, önceden eğitilmiş modelin parametreleri yeni göreve uyacak şekilde yeniden ayarlanır. Buna karşılık, bu çalışmada kullanılan özellik çıkarımı tekniğinde, önceden eğitilmiş model yeni görevdeki görüntülerden özellikler çıkarmak için bir araç olarak kullanılır. Bu yöntemde modelin parametreleri değiştirilmez, sadece özellik çıkarıcı olarak işlev görür. Ardından, bu çıkarılan özellikler, ele alınan spesifik görev için makine öğrenimi modelinin girdileri olarak kullanılmaktadır. Öğrenim aktarımının şematik gösterimi Şekil 3.10'da

sunulmuştur. Girdi olarak kullanılan görüntü, RGB renk kanallarına ayrıldıktan sonra, özellik çıkarımı için önceden eğitilmiş bir model olan ResNet-50'e verilmiştir.

Öğrenim aktarımı, çeşitli alanlarda yaygın olarak uygulanmaktadır. Bilgisayarlı görüde, önceden eğitilmiş evrişimli sinir ağları, görüntü sınıflandırma ve nesne tespiti gibi görüntü analizi görevlerinde devrim yaratmıştır. Doğal dil işlemede, BERT gibi modeller, metne bağlamsal anlayış katarak duygu analizi ve metin sınıflandırmasını zenginleştirmiş ve bu alandaki manzarayı yeniden şekillendirmiştir. Tıp alanında, geniş tıbbi görüntü veri setleri üzerinde önceden eğitilmiş modeller, radyoloji ve patoloji analiz araçlarının geliştirilmesini hızlandırarak tanı doğruluğunu artırmaktadır.

Sonuç olarak, öğrenim aktarımı, bilgi ve uzmanlığı verimli bir şekilde aktararak makine öğrenimi çabalarını ilerletebilen vazgeçilmez bir araçtır. Bu sayede, modellerin minimal veri ve hesaplama kaynağıyla yüksek performans elde etmesini sağlamaktadır. Öğrenim aktarımının bu özellikleri, özellikle sınırlı veri veya hesaplama gücüne sahip araştırmacılar için büyük avantaj sağlamakta ve yapay zeka teknolojilerinin daha geniş bir kullanım alanına yayılmasına katkıda bulunmaktadır.




Şekil 3.10. Öğrenim aktarımı metodunun şematik gösterimi.

3.4.3. ResNet-50

ResNet-50, ya da Residual Network-50, 2015 yılında yayımlanan etkili bir makalede tanımlanan özel bir evrişimli sinir ağıdır (He vd., 2016). Bu ağ, 48 evrişim katmanı, bir MaxPool katmanı ve bir ortalama havuzlama (average pool layer) katmanından oluşan 50 katmanlı bir yapıdan meydana gelmektedir (Şekil 3.11). ResNet-50'yi öne çıkaran özellik, kısayol bağlantıları içeren yenilikçi mimarisidir. Bu bağlantılar, modelin belirli katmanları “atlayabilmesine” olanak tanır. Bu özgün yaklaşım, çok sayıda evrişim katmanı kullanılırken sıkça karşılaşılan gradyan sönümlenmesi sorununu ele almaktadır. Gradyan sönümlenmesi, derin ağlarda eğitim sırasında ağın alt katmanlarına

doğru gradyanların azalması ve dolayısıyla bu katmanları etkili bir şekilde öğrenememesi sorunudur. ResNet-50'nin kısayol bağlantıları, gradyanların ağ boyunca daha kolay akmasını sağlayarak bu sorunu hafifletir.

ResNet-50'nin bu yapısı, derin öğrenme alanında bir dönüm noktası olmuştur. Bu mimari, daha derin ağların eğitilmesini mümkün kılmış ve görüntü sınıflandırma, nesne tespiti gibi birçok bilgisayarlı görü görevinde “state-of-the-art” sonuçlar elde edilmesini sağlamıştır. Ayrıca, ResNet-50'nin öğrenim aktarımı için sıkça kullanılan bir model olması, onun çeşitli alanlardaki uygulamalarda, özellikle sınırlı veri setleriyle çalışırken, tercih edilmesine yol açmıştır.



Şekil 3.11. ResNet-50'nin mimarisi

3.4.4. You Look Only Once (YOLO)


Yolo algoritması, ilk olarak 2016 yılında tanıtılmış olup, o zamandan beri hem görüntülerde hem de videolarda gerçek zamanlı nesne tanıma ve konumlandırma için yaygın olarak bilinmekte ve kullanılmaktadır. Açık kaynak olmasının yanı sıra, yüksek tespit doğruluğu ve hızlı işlem yapabilme yeteneği, ününe önemli ölçüde katkıda bulunmuştur (Redmon vd., 2016). YOLO nesne tespit algoritması, YOLO, YOLOv2, YOLOv3 gibi birçok versiyona sahiptir. YOLOv5'in geliştiricisi Ultralytics, yakın zamanda YOLOv8'i tanıtmış olup, bu versiyon önceki versiyonlara kıyasla hem doğruluk hem de hız açısından önemli iyileştirmeler sergilemektedir (Jocher vd., 2023). Ayrıca, nesne tanımanın yanı sıra sınıflandırma, nesne takibi, poz tahmini ve segmentasyon gibi faaliyetleri de gerçekleştirme yeteneğine sahiptir. YOLOv8, farklı modlar için birden fazla önceden eğitilmiş model içermektedir. Sınıflandırma modu için, 20000 kategoriyi kapsayan 14 milyondan fazla görüntü içeren ImageNet veri seti gibi veri setlerini kullanır. Tespit, segmentasyon ve poz tahmini için modellerin eğitimi, 330000 görüntü ve 80 sınıf içeren COCO veri seti kullanılarak yapılmaktadır (Lin vd., 2015).

YOLOv8'in üç model kategorisi olan tespit, segmentasyon ve sınıflandırma için beş farklı önceden eğitilmiş model bulunmaktadır: YOLOv8n, YOLOv8s, YOLOv8m, YOLOv8l ve YOLOv8x. Bu beş model, parametre sayısı açısından birbirinden farklıdır.

YOLOv8 nano (YOLOv8n), en hızlı ve en kompakt model olarak öne çıkarken, YOLOv8 Extra Large (YOLOv8x) nispeten daha yavaş olmasına rağmen doğruluk açısından daha iyi performans sergiler. YOLOv8 nesne tespiti ve segmentasyon kontrol noktaları, sırasıyla 640 piksel görüntü çözünürlüğünde COCO tespit ve segmentasyon veri setinde eğitilirken, görüntü sınıflandırma modelleri 224 piksel çözünürlükte ImageNet veri seti üzerine eğitilmiştir.

YOLOv8, nesne tespiti alanında son teknoloji bir model olarak, önceki sürümlerine göre önemli mimari değişiklikler ve iyileştirmeler sunar. Şekil 3.12’de gösterilen YOLOv8’in mimarisi, modifiye edilmiş CSPDarknet53 backbone’u kullanır. Bu backbone, YOLOv5’te kullanılan CSPLayer yerine C2f modülünü içerir. C2f modülü, yüksek seviyeli özellikleri bağlamsal bilgilerle birleştirerek tespit doğruluğunu artırır. Bu modül, ağın farklı aşamalarından gelen önemli özellikleri yakalama ve kullanma yeteneğini geliştirir, bu da performansın iyileşmesine katkıda bulunur.

YOLOv8, ayrıca hesaplamaları hızlandırmak için bir spatial pyramid pooling fast (SPPF) katmanı kullanır. SPPF katmanı, özellikleri sabit boyutlu bir haritaya havuzlayarak hesaplamaları hızlandırır. Her evrişim katmanı, batch normalization ve SiLU aktivasyon fonksiyonuna sahiptir, bu da modelin daha hızlı ve daha stabil öğrenmesini sağlar. YOLOv8’in başlık yapısı, nesne olasılığı, sınıflandırma ve regresyon görevlerini bağımsız olarak işlemek için ayrı bir başlık kullanır. Bu ayrı tasarım, her bir dalın kendi görevine odaklanmasını sağlar ve modelin genel doğruluğunu artırır. Bu ayrı yapı, her görevin daha özel bir şekilde işlenmesine ve daha iyi optimize edilmesine olanak tanır.



Şekil 3.12. YOLOv8'in mimarisi (RangeKing, t.y.)


YOLOv8'in çıktı katmanında, nesne olasılığı için sigmoid fonksiyonu kullanılır. Sigmoid fonksiyonu, 0 ile 1 arasında bir olasılık değeri üretir ve bu değer, sınırlayıcı kutunun bir nesne içermesi olasılığını temsil eder. Sınıf olasılıkları için ise softmax fonksiyonu kullanılır. Softmax fonksiyonu, tüm olası sınıflar üzerinde bir olasılık dağılımı sağlar ve nesnenin her bir sınıfa ait olma olasılığını belirtir. YOLOv8, sınırlayıcı kutu kaybı için CIOU (Complete Intersection over Union) ve DFL (Distribution Focal Loss) kullanır. CIOU, örtüşme alanını, merkez noktalar arasındaki mesafeyi ve sınırlayıcı kutuların en-boy oranını dikkate alan gelişmiş bir IoU tabanlı kayıp fonksiyonudur ve daha doğru konumlandırma sağlar. DFL, tahmin edilen değerlerin dağılımına odaklanarak sınırlayıcı kutu tahminlerini iyileştirir. Sınıflandırma kaybı için ise YOLOv8, çok sınıflı sınıflandırma görevleri için etkili olan binary cross-entropy kullanır.

Bu kayıp fonksiyonları, özellikle küçük nesnelerle çalışırken nesne tespiti performansını artırır.

YOLO algoritması, bir dizi temel adımdan oluşur. İlk olarak giriş görüntüsünün modelin beklediği giriş boyutuna uyması için genellikle 640x640 piksel gibi sabit bir boyuta yeniden boyutlandırılmasıyla başlar. Bu yeniden boyutlandırma, modelin farklı boyutlardaki görüntüleri tutarlı bir şekilde işleyebilmesini sağlar. Daha sonra, görüntünün piksel değerleri, modelin gereksinimlerine bağlı olarak [0, 1] aralığında normalleştirilir. Bu işlem, girişi standartlaştırır ve eğitim sırasında daha hızlı yakınsama sağlar.

Görüntü ön işlemden geçirildikten sonra, YOLOv8'in evrişimli sinir ağına beslenir. ESA, görüntüden hiyerarşik özellikler çıkaran birden çok evrişim katmanından oluşur. Bu katmanlar, ilk katmanlarda kenarlar ve dokular gibi düşük seviyeli özellikleri, daha derin katmanlarda ise şekiller ve nesne parçaları gibi daha karmaşık özellikleri yakalar.

YOLO'nun temel özelliği, ızgara tabanlı tahmin mekanizmasında yatar (Şekil 3.13). Görüntü, $S \times S$ 'lik bir ızgaraya bölünür ve her ızgara hücresi sabit sayıda sınırlayıcı kutu tahmin etmekten, güven skorundan ve sınıf olasılıklarından sorumludur. Her sınırlayıcı kutu için model, koordinatları (x, y, genişlik, yükseklik), nesne olma puanını (bir nesnenin varlığını gösteren) ve sınıf olasılıklarını (nesnenin türünü gösteren) tahmin eder. Koordinatlar, ızgara hücresine göre tahmin edilir, bu da nesnelerin görüntü içinde konumlandırılmasına yardımcı olur. Nesne olma puanı, sınırlayıcı kutuda bir nesnenin bulunma olasılığını yansıtan bir güven puanıdır, sınıf olasılıkları ise nesnenin önceden tanımlanmış her bir sınıfa ait olma olasılığını gösterir.



Şekil 3.13. Hücrelere bölünmüş bir görüntü ve 61. hücre için çıkış verileri. Çıkış verisi her bir hücre için hesaplanır

İlk tahminler yapıldıktan sonra, model Maksimum Olmayan Bastırma (NMS) adı verilen bir son işlem adımı uygular. NMS, önemli ölçüde örtüşen gereksiz sınırlayıcı kutuları ortadan kaldırmak ve tespit edilen her nesne için yalnızca en yüksek güven puanına sahip sınırlayıcı kutuyu korumak için kullanılır. Bu adım, yanlış pozitifleri azaltmak ve her nesnenin yalnızca bir kez tespit edilmesini sağlamak için çok önemlidir. Nihai çıktı, her biri tahmin edilen sınıf etiketi ve güven puanıyla açıklanmış filtrelenmiş sınırlayıcı kutulardan oluşur.

YOLO nesne tespiti, günlük yaşamımızın birçok yönü için vazgeçilmez hale getiren birçok farklı alanda uygulamalara sahiptir. Sağlık hizmetleri, tarım, güvenlik gözetimi ve otonom araçlar, kritik bir işlev üstlendiği alanlardan bazılarıdır (Ashraf vd., 2021; Qin vd., 2021; Lippi vd., 2021; Nguyen vd., 2021; Oguine vd., 2022; Paul vd., 2022; Benjumea vd., 2023; Aldughayfiq vd., 2023). Sağlıkta, YOLOv3, cerrahiler sırasında organların gerçek zamanlı lokalizasyonuna yardımcı olur, bu da hastalar arasındaki biyolojik çeşitlilikle başa çıkmada özellikle yararlıdır. Özellikle, bilgisayarlı tomografi (BT) taramalarında böbrek tanıma işleminde süreci hızlandırmak için kullanılmıştır (Lemay, 2019). Tarımda, yapay zekâ ve robot teknolojisi endüstriyi devrim niteliğinde değiştirmiş, YOLO görüntü tabanlı hasat robotlarında kilit bir bileşen olarak yer almıştır. Bu robotlar manuel işçiliğin yerini alarak, hasat için farklı meyve ve sebzeleri verimli bir şekilde tanımlar. Güvenlik gözetimi, geleneksel kullanımın ötesine geçmiş; COVID-19 pandemisi sırasında bireyler arasındaki sosyal mesafe ihlallerini tahmin etmek için kullanılmıştır. YOLO'nun gerçek zamanlı nesne algılama yeteneği, otonom araçlar alanında da vazgeçilmezdir. Otonom araçlar, şeritleri, nesneleri ve yayaları doğru bir şekilde tanımlamak için YOLO'ya güvenir, bu da yol güvenliğini önemli ölçüde artırır. YOLO'nun doğasında var olan gerçek zamanlı yetenekleri, basit görüntü segmentasyon yaklaşımlarına kıyasla üstün bir seçim olmasını sağlar ve otonom ulaşımın geleceğini şekillendirmede kritik bir rol oynar.

3.5. Veri İşleme ve Model Geliştirme

Bu araştırmanın ilk aşaması, veri setini analiz için hazırlamak amacıyla veri ön işleme ve veri artırma tekniklerini içermektedir. Mevcut görüntü veri seti, yaklaşık olarak %65, %20 ve %15 oranlarında eğitim, doğrulama ve test seti olacak şekilde bölünmüştür. Eğitim seti, tüberküloz için 162 ve zatürre için 171 görüntüden oluşurken, doğrulama ve test setleri her iki hastalık sınıfı için sırasıyla 50 ve 35 örnekten oluşmaktadır. Modelin performansını iyileştirmek amacıyla, eğitim veri setine çeşitli veri artırma teknikleri

uygulanmıştır. Bu teknikler arasında görüntü döndürme, yatay ve dikey çevirme, parlaklık ve kontrast ayarlamaları, renk tonu değişiklikleri ve pozlama manipülasyonları yer almaktadır. Bu işlemler sonucunda, tüberküloz sınıfı için 810, zatürre sınıfı için ise 855 eğitim görüntüsü elde edilmiştir. Sınıflar arasında var olan hafif dengesizliği gidermek için pandas kütüphanesinden rastgele alt örnekleme yöntemi kullanılmıştır (McKinney vd., 2010). Bu yöntem, tüberküloz sınıfından görüntü sayısına eşleşecek şekilde zatürre sınıfından rastgele bir alt küme seçer. Bu, modellerin örnek sayısındaki farklılıklar nedeniyle herhangi bir sınıfa karşı önyargılı olmamasını sağlar ve her iki hastalığın özelliklerini eşit ölçüde öğrenmesini sağlar.

Çalışmanın bir sonraki aşaması, nesne tespit modelinin eğitilmesini kapsamaktadır. Tüberküloz sınıfına ait eğitim görüntüleri, başlangıçtaki 162 görüntüden veri artırma teknikleri ile elde edilen genişletilmiş sete dayanarak, YOLOv8 modellerini oluşturmak için 640x640 piksel boyutuna yeniden ölçeklendirilmiştir. Üç farklı önceden eğitilmiş YOLOv8 modeli (YOLOv8m, YOLOv8l ve YOLOv8x) kullanılarak, tüberküloz hücrelerini tespit edebilen üç ayrı model eğitilmiştir. Bu modeller, eğitilebilir parametre sayıları bakımından farklılık gösterdiğinden, her birinin performansı bağımsız olarak değerlendirilmiştir.

Sonraki aşamada, ikili sınıflandırma modellerinin oluşturulmasına odaklanılmıştır. Bu süreç, birden fazla adımı içermektedir. İlk olarak, eğitim görüntüleri 224 x 224 piksel boyutuna yeniden ölçeklendirilmiştir. Ardından, her iki sınıftan (tüberküloz ve pnömoni) gelen görüntüler NumPy (Harris vd., 2020) dizilerine dönüştürülüp, scikit-learn kütüphanesinin standard scaler sınıfı kullanılarak normalize edilmiştir (Pedregosa, 2011). Bu işlem, verileri sıfır ortalama ve bir birim standart sapma ile hizalar. Bu dönüşüm süreci, özellik çıkarma aşaması için kritik öneme sahiptir. Standartlaştırılmış görüntüler, anlamlı ve ayırt edici özelliklerin çıkarılması amacıyla önceden eğitilmiş ResNet-50 modeline gönderilir. Özellik çıkarma aşamasında önceden eğitilmiş olan modelin sınıflandırmada kullanılan tam bağlantılı katmanları kaldırılıp, geri kalan katmanları ise dondurulur. Bu işlem, “öğrenim aktarımı” olarak da bilinir ve modelin genel özellikleri öğrenmiş olan alt katmanlarını yeni bir görev için kullanmamızı sağlar. Diğer bir ifadeyle bu dondurulan katmanlar yeni verilerden özellik çıkarmak için kullanılır. Bu süreç, önceden eğitilmiş modelin büyük veri setlerinden öğrendiği genel özellikleri (kenarlar, dokular, şekiller gibi) yeni veri setimize transfer etmemizi sağlar.


Elde edilen özellikler, çeşitli makine öğrenimi algoritmaları için girdi olarak kullanılabilir. Bu çalışmada dört farklı makine öğrenmesi algoritması (Destek Vektör

Makineleri, Lojistik Regresyon, Naive Bayes ve Rastgele Orman.) bu özellikleri kullanarak eğitilmiştir.

Her modelin optimal performansını sağlamak için, çeşitli hiperparametre kombinasyonları üzerinde parametre optimizasyonu gerçekleştirilmiştir. Bu süreçte, grid search algoritması ve 3 katlı çapraz doğrulama (3-fold cross validation) kullanılarak en uygun parametreler belirlenmiştir. Her model için belirlenen bu optimum parametreler Çizelge 3.1’de detaylandırılmıştır. Elde edilen optimize edilmiş parametrelerle dört farklı makine öğrenmesi modeli geliştirilmiştir. Geliştirilen makine öğrenmesi modellerinin ayrılmış test setleri üzerine performansları test edilip, tüberküloz sınıfına ait olduğu doğru bir şekilde tespit edilen görüntüler daha sonra YOLO modelleri kullanılarak Langhan dev hücrelerinin tespiti. Bu çalışmada izlenen metodoloji Şekil 3.14’te ayrıntılı olarak gösterilmiştir.

Çizelge 3.1. Lojistik Regresyon, Destek Vektör Makineleri, Rastgele Orman ve Naïve Bayes algoritmaları için GridSearch ile optimize edilen hiperparametreler

Hiperparametreler	Makine Öğrenmesi Modelleri			
	DVM	LR	RO	Naïve Bayes
kernel	linear	-	-	-
C	0.1	-	-	-
gamma	1	-	-	-
penalty	-	l2	-	-
solver	-	liblinear	-	-
n_estimators	-	-	75	-
max_depth	-	-	10	-
min_samples_split	-	-	7	-
min_samples_leaf	-	-	2	-
var_smoothing	-	-	-	0.05
priors	-	-	-	None



Şekil 3.14. Çalışmanın metodolojisinin şematik gösterimi

4. ARAŞTIRMA BULGULARI VE TARTIŞMA

Mezbahada kesilen sığırların akciğerlerinin makroskopik muayenesinde plevra ve akciğer parankiminde tipik tüberküller tespit edilmiş ve bu lezyonlardan örnekler alınmıştır (Şekil 4.1).




Şekil 4.1. bTB'den etkilenen akciğerlerin makroskopik görünümü


Tüberküloz mikrofotograflarında, yapay zekaya Langhans dev hücrelerini tanımlama yeteneğini kazandırmak amacıyla Langhans dev hücrelerini içeren karakteristik tüberküllerden alanlar seçildi. Nesne etiketleme işleminden sonra YOLOv8 kullanılarak üç farklı model geliştirilip, bu geliştirilen modellerin performanslarının test set üzerinde değerlendirilebilmesi için ayrı ayrı kaydedilmişlerdir.

Şekil 4.2’de incelenen modellerin eğitilebilir parametre detayları karşılaştırmalı olarak sunulmuştur. Grafikten açıkça görüldüğü üzere, YOLOv8x modeli diğerlerine kıyasla çok daha yüksek sayıda parametreye sahiptir. Bu durum, beklenildiği gibi, YOLOv8x’in daha karmaşık bir yapıya sahip olduğunu göstermektedir. Ayrıca, parametre sayısındaki bu belirgin fark, modelin daha fazla hesaplama kaynağı gerektirdiğine işaret etmektedir. Dolayısıyla, bu karşılaştırma bize sadece modellerin yapısal farklılıklarını değil, aynı zamanda potansiyel performans ve kaynak gereksinimleri hakkında da önemli bilgiler sunmaktadır.

Eğitim sırasında, döngü sayısı 200 olarak belirlenmiş ve aşırı uyumu önlemek amacıyla erken durdurma stratejisi uygulanmıştır. Modelin performansında 30 ardışık döngü boyunca iyileşme gözlenmezse, erken durdurma mekanizması devreye girer. Her biri YOLO modeli için, modelin eğitimi sırasında duyarlılık, kesinlik ve mAP50 performans metriklerinden faydalanılmıştır. Bu metrikler, döngü sayısına bağlı olarak çizilmiş ve sırasıyla Şekil 4.3, Şekil 4.4 ve Şekil 4.5'te gösterilmiştir. Yüksek duyarlılık, modelin ilgili örnekleri tespit etme yeteneğini gösterirken, yüksek kesinlik doğru pozitif tahminlerin oranını belirtir. IoU eşiği 0.50 olarak alındığında, farklı güven seviyelerinde ortalama kesinliği hesaplayan mAP50 metriği, tahmin edilen sınırlayıcı kutuların gerçek konumlarla ne kadar iyi örtüştüğünü yansıtır.




Şekil 4.2. Üç farklı önceden eğitilmiş YOLOv8 modelinin parametre sayısının karşılaştırması.



Şekil 4.3. Tüberküloz veri seti üzerine eğitilmiş üç YOLO modelinin IoU 0.50'deki ortalama kesinlik (mAP50) dağılımı.




Şekil 4.4. Tüberküloz veri seti üzerine eğitilmiş üç farklı YOLO modelinin (x-large, large ve medium) duyarlılık değerlerinin döngü sayısına (epoch) göre değişimi




Şekil 4.5. Tüberküloz veri seti üzerine eğitilmiş üç farklı YOLO modelinin kesinlik değerlerinin döngü sayısına göre değişimi

İkili sınıflandırma modellerinin geliştirilmesinin ardından, 35 görüntüden oluşan özel test seti kullanılarak performansları detaylı bir şekilde değerlendirilmiştir. Dört modelden üçü, tüberküloz vakalarının tespitinde %100 doğruluk oranına ulaşarak üstün bir performans sergilerken, Naïve bayes ile oluşturulan model diğerlerine kıyasla biraz daha düşük bir performans göstermiştir. Bu performans farkının olası nedenleri arasında, Naive Bayes algoritmasının özelliklerin bağımsızlığı varsayımı ve sürekli özellik değerleriyle ilgili kısıtlamaları yer alabilir. Bu dört modelden Lojistik Regresyon modeline ait karışıklık matrisi, buna karşılık gelen ROC eğrisi ve ilgili Eğri Altındaki Alan (AUC) değeri ile birlikte sırasıyla Şekil 4.6 ve Şekil 4.7’de gösterilmiştir. Bu

grafiksel gösterimler, modelin sınıflandırma performansı ve ayırt edici gücü hakkında değerli bilgiler sunmaktadır.



Şekil 4.6. Lojistik regresyon modelinin tüberküloz ve pnömoni sınıflarını sınıflandırma performansını gösteren karmaşıklık matrisi



Şekil 4.7. Lojistik regresyon modelinin tüberküloz ve pnömoni sınıflarını ayırt etme performansını gösteren ROC eğrisi.


İkili sınıflandırma modellerinin performansı; doğruluk, duyarlılık, kesinlik ve F1 skoru metrikleri kullanılarak değerlendirilmiş ve bu sonuçlar Çizelge 4.1’de ayrıntılı olarak verilmiştir. Tüberküloz sınıfı olarak doğru şekilde tanımlanan görüntüler, daha

sonra Langhans dev hücrelerinin tespiti için ikinci bir değerlendirme aşamasına tabi tutulmuştur. Her biri önceden eğitilmiş modellerle eğitilmiş olan üç farklı YOLOv8 modeli: YOLOv8x, YOLOv8l ve YOLOv8m, Langhans dev hücrelerinin lokalizasyonu için kullanılmıştır. Bu modellerin performansları Şekil 4.8’de görselleştirilmiştir. Tüm modeller gayet iyi sonuçlar verirken, YOLOv8x güven puanları açısından benzerlerine kıyasla daha üstün bir performans sergilemiştir. Bu da daha önce bahsedilen modelin parametre sayısı ile ilişkilidir. Şekilden de görüleceği üzere, aynı test görüntüsü üzerinde bulunan iki farklı Langhans dev hücrelerini YOLOv8 x-large modeli 0.93-0.94, YOLOv8 large modeli 0.86-0.88 ve YOLOv8 medium modeli 0.83-0.86 güven skorları ile tespit etmektedir. Bu da YOLOv8’in nesne tespiti ve lokalizasyonu bağlamında tüberküloz hücrelerini doğru ve güvenli bir şekilde tespit etme kabiliyetini göstermektedir.

bTB'nin erken teşhisi için çeşitli antemortem ve postmortem yöntemler kullanılmaktadır; her birinin teşhis açısından avantajları ve dezavantajları vardır. Postmortem tanı, nihai tanıya ulaşmak için yeterli görsel muayene, palpasyon ve bakteriyel izolasyon, histopatoloji ve PCR gibi ileri tanı süreçlerine dayanırken, antemortem yaklaşımlar ya hücresele ya da humoral bağışıklık tepkilerine dayanır. Tip, mutasyon tespiti, filogenetik analiz, moleküler epidemiyoloji ve nedensel mikobakteriler içindeki etkileşimler gibi dizileme ve biyoinformatik araçlar, son zamanlarda bTB teşhisi için giderek daha önemli hale gelmiştir (Borham vd., 2022). Röntgen görüntülerine odaklanan birçok çalışmanın aksine, bu araştırma, sığır akciğer kesitlerinin mikroskopik fotoğraflarından özellik çıkarımı için öğrenim aktarımını kullanan ve ardından Langhans hücrelerini lokalize etmek için YOLOv8'i kullanan makine öğrenimi yöntemlerinin tüberküloz ve pnömoniyi nasıl ayırt edebildiğini göstermiştir.

Çizelge 4.1. Tüberküloz ve pnömoni sınıflandırması için eğitilmiş modellerin performans metrikleri

Modeller	Doğruluk	Duyarlılık	Kesinlik	F1
DVM	0.986	1.000	0.972	0.986
LR	0.986	1.000	0.972	0.986
RO	0.986	1.000	0.972	0.986
Naïve Bayes	0.929	0.857	1.000	0.923



Şekil 4.8. Üç farklı YOLO modelinin Langhans hücrelerini tespit etme durumu ve güven skorları.

5. SONUÇ VE ÖNERİLER

Bu çalışmanın temel hedefi, yapay zekâ teknolojilerinin veteriner patolojisinde, özellikle bovine tüberküloz ve pnömoni türlerinin teşhisinde kullanımının etkinliğini incelemektir. Araştırma, veri ön işleme ve veri artırma teknikleri kullanarak, tüberküloz ve pnömoni sınıflarını dengeli bir şekilde temsil eden genişletilmiş bir eğitim veri seti oluşturmuştur. Bu süreç, sınıflar arasında dengesizliği önlemek ve her iki hastalığın özelliklerini eşit ölçüde öğrenmek için kritik öneme sahiptir. Çalışmada, YOLOv8 modelleri kullanılarak tüberküloz hücrelerinin tespiti gerçekleştirilmiş ve bu modellerin Langhans dev hücrelerini lokalize etmede yüksek hassasiyet sergilediği gözlemlenmiştir. Bu bulgular, tüberkülozun diğer akciğer rahatsızlıklarından ayırt edilmesinde önemli bir katkı sağlamaktadır. Ayrıca, ikili sınıflandırma modelleri için ResNet-50 tabanlı özellik çıkarma ve çeşitli makine öğrenimi algoritmaları kullanılarak yüksek doğruluk oranları elde edilmiştir.

Bu çalışmanın literatürdeki benzer araştırmalardan en önemli farkı, tüberküloz ve pnömoni sınıflandırmasında doku örneklerinin kullanılmasıdır. Literatürde yaygın olarak, tüberküloz ve pnömoni gibi akciğer hastalıklarının teşhisi için göğüs röntgeni görüntüleri kullanılmaktadır. Ancak, bu çalışma, histopatolojik doku örneklerinden elde edilen verilerle sınıflandırma yaparak, daha derinlemesine ve spesifik bir analiz sunmaktadır. Bu yaklaşım, özellikle doku düzeyinde hastalıkların daha hassas bir şekilde teşhis edilmesine olanak tanımaktadır.

Ayrıca, bu çalışmada YOLOv8 modelleri kullanılarak tüberküloz hücrelerinin lokalizasyonu gerçekleştirilmiştir. Literatürde, genellikle akciğer görüntüleri üzerinden genel hastalık teşhisi yapılırken, bu çalışmada YOLOv8 modelleri ile Langhans dev hücrelerinin tespiti sağlanmıştır. Bu, tüberkülozun diğer akciğer rahatsızlıklarından ayırt edilmesinde önemli bir yenilik sunmaktadır. YOLOv8'in sağladığı yüksek hassasiyet, tüberküloz hücrelerinin doğru bir şekilde lokalize edilmesine olanak tanıyarak, teşhis süreçlerini daha etkili hale getirmektedir. Bu yenilikçi yaklaşım, veteriner patolojisinde YZ'nin kullanımını daha ileri bir seviyeye taşımakta ve literatürdeki mevcut yöntemlere kıyasla daha detaylı bir analiz imkanı sunmaktadır.

Günümüzde yapay zekâ teknolojileri, hayatımızın birçok alanında olduğu gibi veteriner hekimlik alanında da hızla yaygınlaşmaktadır. Özellikle patoloji branşında, YZ'nin hastalık teşhisi ve ayırıcı tanı konusunda sunduğu imkanlar, gelecek vadeden bir potansiyel ortaya koymaktadır. Bu teknolojik ilerlemenin, patologların çalışmalarına

önemli bir destek sağlaması ve teşhis süreçlerini hızlandırması beklenmektedir. YZ'nin sağladığı bu avantajlar, özellikle hızlı karar vermenin kritik olduğu durumlarda büyük önem taşımaktadır. Patologların iş yükünü hafifletmenin yanı sıra, teşhis doğruluğunu artırarak hastaların daha hızlı ve etkili bir şekilde tedavi edilmesine olanak tanımaktadır.

Veteriner patolojisi alanında da YZ'nin kullanımı, hayvan hastalıklarının hızlı ve doğru teşhisinde çığır açıcı bir ilerleme sağlamaktadır. Bu çalışma, YZ'nin histopatolojik preparatlarda bovine tüberküloz ve diğer pnömoni türlerinin teşhisindeki potansiyelini açıkça ortaya koymuştur. Özellikle kariyerlerinin başındaki genç veteriner patologlar için bu teknoloji, mesleki gelişimlerinde ve teşhis yeteneklerini geliştirmede çok değerli bir araç sunmaktadır. YZ'nin sağladığı hızlı ve doğru teşhis imkanları, veteriner hekimlerin daha etkili tedavi stratejileri geliştirmelerine ve hayvan sağlığını koruma çabalarına önemli katkılar sağlamaktadır.

YZ'nin veteriner patolojisine entegrasyonu, sadece mevcut patologlar için değil, aynı zamanda veteriner hekimlik eğitimi alan öğrenciler için de önemli fırsatlar sunmaktadır. Bu teknoloji, öğrencilerin daha kapsamlı ve pratik bir eğitim almalarına olanak tanıyarak, mezun olduklarında daha donanımlı profesyoneller olmalarını sağlayacaktır. Ayrıca, YZ destekli sistemler, nadir görülen hastalıkların teşhisinde ve karmaşık vakaların analizinde veteriner hekimlere değerli bir kaynak sunarak, mesleki gelişimlerine katkıda bulunacaktır.

YZ'nin veteriner patolojisinde kullanımı, aynı zamanda araştırma ve geliştirme faaliyetlerini de hızlandırma potansiyeline sahiptir. Büyük veri setlerinin hızlı ve etkili bir şekilde analiz edilmesi, yeni tedavi yöntemlerinin geliştirilmesine ve mevcut protokollerin optimize edilmesine yardımcı olabilir. Bu, veteriner ilaç endüstrisinde inovasyonu teşvik edebilir ve daha etkili, daha az yan etkiye sahip tedavilerin ortaya çıkmasını sağlayabilir.

YZ'nin veteriner patolojisinde kullanımının yaygınlaşması, disiplinler arası iş birliğini teşvik etme potansiyeline sahiptir. Veteriner hekimler, patologlar, bilgisayar bilimcileri ve veri analistleri arasındaki iş birliği, daha sofistike ve etkili YZ çözümlerinin geliştirilmesine olanak tanıyacaktır. Bu tür iş birlikleri, veteriner hekimliğin geleceğini şekillendirmede ve hayvan sağlığı alanında yenilikçi çözümler üretmede kritik bir rol oynayacaktır.

Sonuç olarak, YZ'nin veteriner patolojisinde kullanımı hem mevcut patoloğlara hem de geleceğin veteriner hekimlerine muazzam faydalar sağlayacak devrim niteliğinde bir gelişmedir. Bu teknolojinin sunduğu hızlı, doğru ve güvenilir teşhis imkanları, hayvan

sağlığını koruma ve iyileştirme çabalarında çok önemli bir rol oynayacaktır. Bu çalışma, YZ'nin veteriner hekimlikteki potansiyelini ve sağladığı avantajları açık bir şekilde ortaya koyarak, gelecekteki araştırmalar ve uygulamalar için sağlam bir temel oluşturmuştur. Veteriner patolojisinde YZ kullanımının daha da geliştirilmesi ve yaygınlaştırılması, hayvan sağlığı alanında önemli ilerlemelere yol açacak ve veteriner hekimliğin geleceğini şekillendirecektir.

Gelecekte, YZ'nin veteriner patolojisinde daha geniş bir yelpazede uygulanması, farklı hayvan türlerinde ve çeşitli hastalıklarda daha kapsamlı teşhis ve tedavi yöntemlerinin geliştirilmesine olanak tanıyacaktır. Bu, veteriner hekimlerin daha geniş bir bilgi tabanına erişmelerini ve daha etkili tedavi stratejileri geliştirmelerini sağlayacaktır. Ayrıca, YZ'nin sürekli gelişen doğası, veteriner hekimlerin ve patoloğların bu teknolojiyi kullanarak daha yenilikçi ve etkili çözümler üretmelerine olanak tanıyacaktır.

KAYNAKLAR

- Aldughayfiq, B., Ashfaq, F., Jhanjhi, N. Z. ve Humayun, M. (2023). YOLO-Based Deep Learning Model for Pressure Ulcer Detection and Classification. *Healthcare*, 11(9), 1222. <http://dx.doi.org/10.3390/healthcare11091222>.
- Ashraf, A., Imran, M., Qahtani, A., Alsufyani, A., Almutiry, O., Mahmood, A., Habib, M. (2021). Weapons Detection for Security and Video Surveillance Using CNN and YOLO-V5s. *Computers, Materials & Continua*, 70(2), 2761-2775. <http://dx.doi.org/10.32604/cmc.2022.018785>.
- Bangare, S., Rajankar, H., Patil, P., Nakum, K. ve Paraskar, G. (2022). Pneumonia Detection and Classification using CNN and VGG16. *International Journal of Advanced Research in Science, Communication and Technology*, 2(3), 771-779. <http://dx.doi.org/10.48175/IJARSCT-3851>.
- Becker, A. S., Blüthgen, C., Phi van, V. D., Sekaggya-Wiltshire, C., Castelnovo, B., Kambugu, A., Frauenfelder, T. (2018). Detection of tuberculosis patterns in digital photographs of chest X-ray images using Deep Learning: Feasibility study. *The International Journal of Tuberculosis and Lung Disease*, 22(3), 328-335. <http://dx.doi.org/10.5588/ijtld.17.0520>.
- Benjumea, A., Teeti, I., Cuzzolin, F. ve Bradley, A. (2023). YOLO-Z: Improving small object detection in YOLOv5 for autonomous vehicles. *arXiv preprint arXiv:2112.11798*. <http://dx.doi.org/10.48550/arXiv.2112.11798>.
- Bhartiya, P., Yadav, S., Gupta, A. ve Gupta, D. (2021). Pneumonia Detection Using CNN and ANN Based on Deep Learning Approach. *Emerging Technologies for Healthcare* içinde (181-201 s). John Wiley & Sons, Ltd. <http://dx.doi.org/10.1002/9781119792345.ch7>.
- Bişkin, O., Kırbaş, İ. ve Çelik, A. (2023). A fast and time-efficient glitch classification method: A deep learning-based visual feature extractor for machine learning algorithms. *Astronomy and Computing*, 42, 100683. <http://doi.org/10.1016/j.ascom.2022.100683>.
- Borham, M., Oreiby, A., El-Gedawy, A., Hegazy, Y., Khalifa, H. O., Al-Gaabary, M. ve Matsumoto, T. (2022). Review on Bovine Tuberculosis: An Emerging Disease Associated with Multidrug-Resistant Mycobacterium Species. *Pathogens*, 11(7), 715. <http://doi.org/10.3390/pathogens11070715>.
- Canal, A. M., Pezzone, N., Cataldi, A., Zumarraga, M., Larzabal, M., Garbaccio, S., Rodriguez-Bertos, A. (2017). Immunohistochemical detection of pro-inflammatory and anti-inflammatory cytokines in granulomas in cattle with

natural Mycobacterium bovis infection. *Research in Veterinary Science*, 110, 34-39. <https://doi.org/10.1016/j.rvsc.2016.10.006>

Celik, A. (2023). A fast and time-efficient machine learning approach to dark matter searches in compressed mass scenario. *The European Physical Journal C*, 83(12), 1150.

Celik, A. (2024). Exploring Hidden Signal: Fine-Tuning ResNet-50 for Dark Matter Detection. *Computer Physics Communications*, 305, 109348. <http://doi.org/10.1016/j.cpc.2024.109348>.

Celik, A. ve Seveli, O. (2022). Predicting Traffic Accident Severity Using Machine Learning Techniques. *Türk Doğa ve Fen Dergisi*, 11(3), 79-83.

Chan, H. P., Samala, R. K., Hadjiiski, L. M. ve Zhou, C. (2020). Deep Learning in Medical Image Analysis. G. Lee ve H. Fujita (Ed.), *Deep Learning in Medical Image Analysis: Challenges and Applications* içinde (3-21 s). Cham: Springer International Publishing. http://dx.doi.org/10.1007/978-3-030-33128-3_1.

Cortes, C. ve Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273-297. <http://dx.doi.org/10.1007/BF00994018>.

Deng, L. ve Platt, J. (2014). Ensemble Deep Learning for Speech Recognition. *Proc. Interspeech* (1915-1919 s). <http://dx.doi.org/10.21437/Interspeech.2014-433>.

Domingo, M., Vidal, E. ve Marco, A. (2014). Pathology of bovine tuberculosis. *Research in Veterinary Science*, 97, 20-29. <http://dx.doi.org/10.1016/j.rvsc.2014.03.017>.

Fujiyoshi, H., Hirakawa, T. ve Yamashita, T. (2019). Deep learning-based image recognition for autonomous driving. *IATSS Research*, 43(4), 244-252. <https://dx.doi.org/10.1016/j.iatssr.2019.11.008>

Harris, C. R., Millman, K. J., van der Walt, S. J., Gommers, R., Virtanen, P., Cournapeau, D., Oliphant, T. E. (2020). Array programming with NumPy. *Nature*, 585(7825), 357-362. <https://dx.doi.org/10.1038/s41586-020-2649-2>

He, K., Zhang, X., Ren, S. ve Sun, J. (2016). Deep Residual Learning for Image Recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (770-778 s).

HumanSignal. (2024, 1 Mart). *LabelImg* [Bilgisayar yazılımı]. Github. <https://github.com/HumanSignal/labelImg>.

- Jocher, G., Chaurasia, A. ve Qiu, J. (2023). *Ultralytics YOLOv8* (Version 8.0.0) [Bilgisayar yazılımı]. Github. <https://github.com/ultralytics/ultralytics>.
- Kant, S. ve Srivastava, M. M. (2018). Towards Automated Tuberculosis detection using Deep Learning. *IEEE Symposium Series on Computational Intelligence (SSCI)* (1250-1253 s).
- Ker, J., Wang, L., Rao, J. ve Lim, T. (2018). Deep Learning Applications in Medical Image Analysis. *IEEE Access*, 6 (9375-9389 s).
- Krishnamoorthy, N., Nirmaladevi, K., Kumaravel, T., Sanjay Nithish, K. S., Sarathkumar, S. ve Sarveshwaran, M. (2022). Diagnosis of Pneumonia Using Deep Learning Techniques. *Second International Conference on Advances in Electrical, Computing, Communication and Sustainable Technologies (ICAECT)* (1-5 s).
- Kumari, L. V. R., Bokkolla, P., Syeeda, S. F., Gudala, S. P. ve Dasandla, M. (2021). Detection of pneumonia using Deep Learning. *5th International Conference on Trends in Electronics and Informatics (ICOEI)* (1272-1279 s).
- Kuo, K. M., Talley, P. C., Huang, C. H. ve Cheng, L. C. (2019). Predicting hospital-acquired pneumonia among schizophrenic patients: A machine learning approach. *BMC Medical Informatics and Decision Making*, 19(1), 42. <http://dx.doi.org/10.1186/s12911-019-0792-1>.
- Lin, T.Y., Maire, M., Belongie, S., Bourdev, L., Girshick, R., Hays, J., Dollár, P. (2015). Microsoft COCO: Common Objects in Context. *In Computer Vision–ECCV 2014: 13th European Conference* (740-755 s). Zurich, Switzerland.
- Lippi, M., Bonucci, N., Carpio, R. F., Contarini, M., Speranza, S. ve Gasparri, A. (2021). A YOLO-Based Pest Detection System for Precision Agriculture. *29th Mediterranean Conference on Control and Automation (MED)* (342-347 s).
- McKinney, W. ve others. (2010). Data structures for statistical computing in python. *Proceedings of the 9th Python in Science Conference* (51-56 s). Austin, TX.
- Mollenhorst, H., Ducro, B. J., De Greef, K. H., Hulsegge, I. ve Kamphuis, C. (2019). Boosted trees to predict pneumonia, growth, and meat percentage of growing-finishing pigs1. *Journal of Animal Science*, 97(10), 4152-4159. <http://dx.doi.org/10.1093/jas/skz274>.
- More, K., Jawale, P., Bhattad, S. ve Upadhyay, J. (2021). Pneumonia Detection using Deep Learning. *International Conference on Smart Generation Computing, Communication and Networking (SMART GENCON)* (1-5 s).

- Mwendo, I., Gikunda, K. ve Maina, A. (2023). Deep transfer learning for detecting Covid-19, Pneumonia and Tuberculosis using CXR images-A Review. *arXiv preprint arXiv:2303.16754*. <http://dx.doi.org/10.48550/arXiv.2303.16754>.
- Nguyen, H. H., Ta, T. N., Nguyen, N. C., Bui, V. T., Pham, H. M. ve Nguyen, D. M. (2021). YOLO Based Real-Time Human Detection for Smart Video Surveillance at the Edge. *2020 IEEE Eighth International Conference on Communications and Electronics (ICCE)* (439-444 s).
- Noda, K., Yamaguchi, Y., Nakadai, K., Okuno, H. G. ve Ogata, T. (2015). Audio-visual speech recognition using deep learning. *Applied Intelligence*, 42(4), 722-737. <http://dx.doi.org/10.1007/s10489-014-0629-7>.
- Oguine, K. J., Oguine, O. C. ve Bisallah, H. I. (2022). YOLO v3: Visual and Real-Time Object Detection Model for Smart Surveillance Systems(3s). *5th Information Technology for Education and Development (ITED)* (1-8 s).
- O'Reilly, L. M. ve Daborn, C. J. (1995). The epidemiology of Mycobacterium bovis infections in animals and man: A review. *Tubercle and Lung Disease*, 76, 1-46. [http://dx.doi.org/10.1016/0962-8479\(95\)90591-X](http://dx.doi.org/10.1016/0962-8479(95)90591-X).
- Ozmen, O. (2009). Immunohistochemical detection of C-reactive protein, serum Amyloid-A, caspase and Tumor Necrosis Factor- α in mediastinal lymph nodes in cattle with tuberculosis. *Revue de Médecine Vétérinaire*, 160(6), 288-292.
- Ozmen, O., Kurşun, O. ve Ozcelik, M. (2005). Bovine tuberculosis in Burdur, southern Turkey: Epidemiological, pathological and economic study. *The International Journal of Tuberculosis and Lung Disease*, 9(12), 1398-1402.
- Panicker, R. O., Kalmady, K. S., Rajan, J. ve Sabu, M. K. (2018). Automatic detection of tuberculosis bacilli from microscopic sputum smear images using deep learning methods. *Biocybernetics and Biomedical Engineering*, 38(3), 691-699. <http://dx.doi.org/10.1016/j.bbe.2018.05.007>.
- Pascual-Linaza, A. V., Gordon, A. W., Stringer, L. A. ve Menzies, F. D. (2017). Efficiency of slaughterhouse surveillance for the detection of bovine tuberculosis in cattle in Northern Ireland. *Epidemiology & Infection*, 145(5), 995-1005. <http://dx.doi.org/10.1017/S0950268816003095>.
- Patel, M., Sojitra, A., Patel, Z. ve Bohara, M. H. (2021). Pneumonia Detection Using Transfer Learning. *International Journal of Engineering Research & Technology*, 10(10). <http://dx.doi.org/10.17577/IJERTV10IS100105>.
- Paul, S., Ahad, D. M. T. ve Hasan, M. M. (2022, 27 Aralık). Brain Cancer Segmentation Using YOLOv5 Deep Neural Network. *arXiv preprint arXiv:2212.13599*.

- Pedregosa, F. (2011). Scikit-learn: Machine learning in python Fabian. *Journal of machine learning research*, 12, 2825.
- Pereira, L. E. C., Ferraudo, A. S., Panosso, A. R., Carvalho, A. A. B., Mathias, L. A., Saches, A. C., Ancêncio, R. A. (2020). Machine Learning to predict tuberculosis in cattle from the state of Sao Paulo, Brazil. *European Journal of Public Health*, 30(Supplement_5), ckaa166.849. <https://doi.org/10.1093/eurpub/ckaa166.849>.
- Puttagunta, M. K. ve Ravi, S. (2021). Detection of Tuberculosis based on Deep Learning based methods. *International E- Conference on Data Analytics, Intelligent Systems and Information Security & ICDIIS* (12004 s).
- Qin, Z., Wang, W., Dammer, K.-H., Guo, L. ve Cao, Z. (2021). Ag-YOLO: A Real-Time Low-Cost Detector for Precise Spraying With Case Study of Palms. *Frontiers in Plant Science*, 12, 753603. <https://doi.org/10.3389/fpls.2021.753603>.
- Račić, L., Popović, T., Šandi, S., ve others. (2021). Pneumonia detection using deep learning based on convolutional neural network. *25th International Conference on Information Technology (IT)* (1-4 s).
- Rahman, T., Khandakar, A., Kadir, M. A., Islam, K. R., Islam, K. F., Mazhar, R., Chowdhury, M. E. H. (2020). Reliable Tuberculosis Detection Using Chest X-Ray With Deep Learning, Segmentation and Visualization. *IEEE Access*, 8, 191586-191601.
- RangeKing. (t.y.). *GitHub repository*. Erişim adresi <https://github.com/RangeKing> (Son Erişim Tarihi: 01/08/2024).
- Redmon, J., Divvala, S., Girshick, R. ve Farhadi, A. (2016). You Only Look Once: Unified, Real-Time Object Detection. *Proceedings of the IEEE conference on computer vision and pattern recognition* (779-788 s). Las Vegas, NV, USA.
- Sevtekin, M. ve Ozmen, O. (2018). Immunohistochemical examination of osteopontin and sirtuin-1 expression in cattle tuberculosis. *Biotechnic & Histochemistry*, 93(6), 405-410.
- Shen, D., Wu, G. ve Suk, H.-I. (2017). Deep Learning in Medical Image Analysis. *Annual Review of Biomedical Engineering*, 19(1), 221-248. <http://dx.doi.org/10.1146/annurev-bioeng-071516-044442>.
- Shmatko, A., Ghaffari Laleh, N., Gerstung, M. ve Kather, J. N. (2022). Artificial intelligence in histopathology: Enhancing cancer research and clinical oncology. *Nature Cancer*, 3(9), 1026-1038. <http://dx.doi.org/10.1038/s43018-022-00436-4>.

- Stański, K., Lycett, S., Porphyre, T. ve Bronsvoort, B. M. de C. (2021). Using machine learning improves predictions of herd-level bovine tuberculosis breakdowns in Great Britain. *Scientific Reports*, 11(1), 2208. <http://dx.doi.org/10.1038/s41598-021-81716-4>.
- Venkataramana, L., Prasad, D. V. V., Saraswathi, S., Mithumary, C. M., Karthikeyan, R. ve Monika, N. (2022). Classification of COVID-19 from tuberculosis and pneumonia using deep learning techniques. *Medical & Biological Engineering & Computing*, 60(9), 2681-2691. <http://dx.doi.org/10.1007/s11517-022-02632-x>.
- World Health Organization. (2020). *Global tuberculosis report 2020: Executive summary*. World Health Organization: Erişim adresi <https://iris.who.int/handle/10665/337538>
- Wu, M. ve Chen, L. (2015). Image recognition based on deep learning. *Chinese Automation Congress (CAC)* (542-546 s).
- Zak, M. ve Krzyżak, A. (2020). Classification of Lung Diseases Using Deep Learning Models. *International conference on Computational Science* (621-634 s).