

**T.C.
SAKARYA UYGULAMALI BİLİMLER ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**HAYVANSAL GIDALARDA DERİN ÖĞRENME İLE
TÜBERKÜLOZ TESPİTİ**

YÜKSEK LİSANS TEZİ

Mustafa Burkay ÖZDEMİR

Enstitü Anabilim Dalı : Bilgisayar MÜHENDİSLİĞİ

Tez Danışmanı : Doç. Dr. Ekin EKİNCİ

OCAK 2025

T.C.
SAKARYA UYGULAMALI BİLİMLER ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

HAYVANSAL GIDALARDA DERİN ÖĞRENME İLE
TÜBERKÜLOZ TESPİTİ

YÜKSEK LİSANS TEZİ

Mustafa Burkey ÖZDEMİR

Enstitü Anabilim Dalı : Bilgisayar MÜHENDİSLİĞİ

Bu tez 22/01/2025 tarihinde aşağıdaki jüri üyeleri tarafından oy birliği ile kabul edilmiştir.

JÜRİ	BAŞARI DURUMU
Jüri Başkanı: Doç. Dr. Ekin EKİNCİ	BAŞARILI
Üye: Dr. Öğr. Üyesi Fatih VARÇIN	BAŞARILI
Üye: Dr. Öğr. Üyesi Furkan GÖZ	BAŞARILI

BEYAN

Tez içindeki tüm verilerin akademik kurallar çerçevesinde tarafımdan elde edildiğini, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun şekilde sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim

Mustafa Burkay ÖZDEMİR

22/01/2025

TEŞEKKÜR

İlk ders dönemimden, mezuniyetime kadar olan bu süreçte; hangi konu olursa olsun bilgisini esirgemeyen, kapısı her zaman açık olan, öğretmekten asla çekinmeyen, akademik gelişimime ve bu tezin yazılmasına bilgi birikimiyle çok büyük katkılar sunan sevgili Doç. Dr. Ekin Ekinci hocama ve bilgileriyle bizi aydınlatan, yol gösteren, bizim için çabalayan sevgili Doç. Dr. Zeynep Garip hocama sonsuz teşekkürlerimi sunuyorum.

İÇİNDEKİLER

TEŞEKKÜR	i
İÇİNDEKİLER	ii
KISALTMALAR	iv
TABLolar LİSTESİ.....	v
ŞEKİLLER LİSTESİ.....	vi
ÖZET.....	vii
ABSTRACT	viii

BÖLÜM 1.

GİRİŞ	1
-------------	---

BÖLÜM 2.

LİTERATÜR ÖZETİ	4
2.1. Hayvansal Gıdalarda Geleneksel Tüberküloz Tespit Yöntemleri	4
2.2. Derin Öğrenme Tabanlı Tüberküloz Tespiti	5
2.3. Hayvansal Gıdalarda Tüberküloz Tespiti için Derin Öğrenme Uygulamaları..	6

BÖLÜM 3.

MATERYAL VE METOT	8
3.1. Veri Kümesi	8
3.1.1. Veri ön işleme süreci.....	9
3.2. Evrişimsel Sinir Ağı.....	12
3.2.1. Evrişimsel sinir ağlarına giriş	12
3.2.2. Evrişimsel sinir ağlarının çeşitleri.....	13
3.2.2.1. ResNet-50.....	13

3.2.2.2. DarkNet-53.....	16
3.2.2.3. MobileNet-v2	19
3.2.2.4. GoogleNet	20
3.2.2.5. EfficientNet-b0.....	23
3.2.3. Transfer öğrenme	25

BÖLÜM 4.

DENEYSEL SONUÇLAR..... 26

4.1. Model Parametreleri ve Değerlendirme Metrikleri	26
4.2. Model Eğitim Süreçleri	33
4.3. Deneysel Sonuçlar	33
4.3.1. ResNet-50 ve optimizasyon algoritmaları performans değerlendirmesi..	34
4.3.2. Darknet-53 ve optimizasyon algoritmaları performans değerlendirmesi	37
4.3.3. MobileNet-v2 ve optimizasyon algoritmaları performans değerlendirmesi	39
4.3.4. GoogleNet ve optimizasyon algoritmaları performans değerlendirmesi .	41
4.3.5. EfficientNet-b0 ve Optimizasyon Algoritmaları Performans Değerlendirmesi	43

BÖLÜM 5.

SONUÇ VE ÖNERİLER..... 51

KAYNAKÇA 53

EKLER..... 61

KISALTMALAR

AB	: Attention Block (Dikkat Bloğu)
Adam	: Adaptive Moment Estimation (Uyarlamalı Moment Tahmini)
bTB	: Bovine Tuberculosis (Sığır Veremi)
CNN	: Convolutional Neural Network (Evrimsel Sinir Ağı)
CPU	: Central Processing Unit (Merkezi İşlem Birimi)
DarkNet-53	: Darknet 53 (Karanlık Ağ 53)
DF	: Dilated Fusion Block (Genişletilmiş Birleştirme Bloğu)
DL	: Deep Learning (Derin Öğrenme)
EfficientNet-b0	: Efficient Network Base 0 (Verimli Ağ Temel 0)
FN	: False Negative (Yanlış Negatif)
FP	: False Positive (Yanlış Pozitif)
GoogleNet	: Google Network (Google Ağı)
MobileNet-v2	: Mobile Network Version 2 (Mobil Ağ Sürüm 2)
ResNet-50	: Residual Network 50 (Artık Ağ 50)
RmsProp	: Root Mean Square Propagation (Kök Ortalama Kare Yayılımı)
TP	: True Positive (Doğru Pozitif)
TN	: True Negative (Doğru Negatif)
U-Net	: U-shaped Network (U-şekilli Ağ)
WHO	: World Health Organization (Dünya Sağlık Örgütü)
X-ray	: X-ray (Röntgen)

TABLolar LİSTESİ

Tablo 4.1 Evriřimli sinir ağı model parametreleri	30
Tablo 4.2 Önerilen ResNet-50 mimarisinin detayları	30
Tablo 4.3 Önerilen DarkNet-53 mimarisinin detayları	31
Tablo 4.4 Önerilen MobileNet-v2 mimarisinin detayları	31
Tablo 4.5 Önerilen GoogleNet mimarisinin detayları.....	31
Tablo 4.6 Önerilen EfficientNet-b0 mimarisinin detayları	32
Tablo 4.7 Veri artırma uygulanmadan yapılan deneysel sonuçlar	33
Tablo 4.8 Geleneksel Veri Artırma ile Deneysel sonuçlar	34
Tablo 4.9 GAN ile Artırılmış Verilerin Deneysel sonuçları	34

ŞEKİLLER LİSTESİ

Şekil 3.1 Önerilen metodolojinin mimarisi	8
Şekil 3.2 Sağlıklı (solda) ve bTB ile enfekte (sağda) sığır eti görüntü örnekleri.....	9
Şekil 3.3 Kullanılan veri artırma teknikleri örnekleri	11
Şekil 3.4 ResNet-50 mimari yapısı	15
Şekil 3.5 DarkNet-53 mimari yapısı	18
Şekil 3.6 MobileNet-v2 mimari yapısı.....	20
Şekil 3.7 GoogleNet mimari yapısı.....	23
Şekil 3.8 EfficientNet-b0 mimari yapısı	25
Şekil 4.1 Karmaşıklık Matrisi	29
Şekil 4.2 ResNet-50 için karmaşıklık matrisi (a) RMSProp, (b) Adam (c) SGDM.....	35
Şekil 4.3 DarkNet-53 için karmaşıklık matrisi (a) RMSProp, (b) Adam (c) SGDM.....	37
Şekil 4.4 MobileNet-v2 için karmaşıklık matrisi (a) RMSProp, (b) Adam (c) SGDM..	40
Şekil 4.5 GoogleNet için karmaşıklık matrisi (a) RMSProp, (b) Adam (c) SGDM	42
Şekil 4.6 EfficientNet-b0 için karmaşıklık matrisi (a) RMSProp, (b) Adam (c) SGDM	44
Şekil 4.7 ResNet-50 (sgdm) için kayıp grafiği	45
Şekil 4.8 DarkNet-53 (sgdm) için kayıp grafiği.....	46
Şekil 4.9 MobileNet-v2 (Adam) için kayıp grafiği.....	47
Şekil 4.10 GoogleNet (sgdm) için kayıp grafiği	48
Şekil 4.11 EfficientNet-b0 (sgdm) için kayıp grafiği.....	49
Şekil 4.12 Kayıp grafikleri için göstergeler	50
Şekil A.1: ResNet-50 Eğitim Grafikleri: (a)SGDM. (b)Adam. (c)Rmsprop	61
Şekil A.2: GoogleNet Eğitim Grafikleri: (a)SGDM. (b)Adam. (c)Rmsprop.....	62
Şekil A.3: EfficientNet Eğitim Grafikleri: (a)SGDM. (b)Adam. (c)Rmsprop	63
Şekil A.4: DarkNet-53 Eğitim Grafikleri: (a)SGDM. (b)Adam. (c)Rmsprop	64
Şekil A.5: MobileNet-v2 Eğitim Grafikleri: (a)SGDM. (b)Adam. (c)Rmsprop.....	65

HAYVANSAL GIDALARDA DERİN ÖĞRENME İLE TÜBERKÜLOZ TESPİTİ

ÖZET

Sığır tüberkülozu (*bTB*), *Mycobacterium tuberculosis* (*MTBC*) bir üyesi olan *Mycobacterium bovis*'in neden olduğu zoonotik bulaşıcı hastalıktır. Bu hastalık sığırları etkilemekle birlikte diğer hayvanları ve insanları da enfekte edebilmekte ve ciddi sağlık sorunlarına yol açmaktadır. Et ve pastörize edilmemiş süt gibi kontamine hayvansal ürünlerin tüketilmesi yoluyla insanlara bulaşabilen bTB, gıda güvenliği ve halk sağlığının korunması için incelenmesi gereken bir konudur. Hayvansal ürünlerde bTB'nin tespit edilmesi, semptomların karmaşıklığı ve inceliği nedeniyle zordur. Bu hastalığın tespiti, özel teknikler ve uzmanlık gerektirir. Derin Öğrenme (*DL*) yaklaşımları, özellikle görüntü analizi ve örüntü tanıma gibi tıbbi teşhis alanlarında sıklıkla kullanılmaktadır. *DL* uygulamaları, insan göğüs röntgenlerinde tüberküloz tespiti için sıklıkla tercih edilen bir yöntem iken hayvansal ürünlerde bTB tespitine odaklanan çalışmalarda ciddi bir boşluk vardır. Bu çalışma, et ürünlerindeki bTB'yi tespit etmek için bir Evrişimsel Sinir Ağı (*CNN*) yaklaşımı önererek literatürdeki bu boşluğu kapatmayı hedeflemektedir. Çalışmanın veri kümesi tüberkülozla mücadele vakıfları ve veterinerlik yayınları da dahil olmak üzere çeşitli güvenilir ve bilimsel kaynaklardan elde edilen bTB ile enfekte ve sağlıklı sığır eti görüntülerinden oluşmaktadır. Veri kümesi, yüksek kaliteli görüntüler sağlama amacıyla dikkatlice seçilmiştir. Veri kümesini dengelemek ve modelin öğrenme yeteneklerini geliştirmek için kapsamlı veri artırma teknikleri uygulanmıştır. Elde edilen veri kümesi beş farklı *CNN* mimarisi (*ResNet-50*, *DarkNet-53*, *MobileNet-v2*, *GoogleNet* ve *EfficientNet-b0*) ile modellenmiştir. Her modelin performansı sorgulanırken doğruluk, kesinlik, geri çağırma ve *F1*-skoru gibi çeşitli ölçütlere göre değerlendirmeler yürütülmüştür. Oluşturulan modellerin yüksek doğruluk oranları, *DL* tekniklerinin et ürünlerinde bTB tespitini otomatikleştirme ve iyileştirme potansiyelinin altını çizmektedir. bTB ile enfekte etlerin hızlı ve doğru bir şekilde tespit edilebilmesi, gıda güvenliği önlemlerini önemli ölçüde arttıracak ve tüberkülozun insanlara bulaşma riskini azaltacaktır. Buna ek olarak, *DL* modellerinin kullanımı, insan hatalarını azaltarak daha yüksek hassasiyetle tutarlı ve objektif sonuçlar sağlayacaktır. Gelecekteki çalışmalar, model performansını daha da artırmak için farklı derin öğrenme mimarilerinin ve daha çok veri toplanarak daha geniş veri kümelerinin incelenmesine odaklanacaktır.

Anahtar Kelimeler: derin öğrenme, sınıflandırma, sığır tüberkülozu, et ürünleri, Evrişimsel Sinir Ağı, *CNN*, gıda güvenliği, zoonoz hastalıklar, *Mycobacterium Bovis*

DETECTION OF TUBERCULOSIS IN ANIMAL-BASED FOODS USING DEEP LEARNING

ABSTRACT

Bovine tuberculosis (bTB) is a zoonotic infectious disease caused by *Mycobacterium bovis*, a member of the *Mycobacterium tuberculosis* complex (MTBC). Although this disease primarily affects cattle, it can also infect other animals and humans, leading to serious health concerns. Because bTB can be transmitted to humans through the consumption of contaminated animal products such as meat and unpasteurized milk, it is an issue of significant importance for food safety and public health. Detecting bTB in animal products is challenging due to the complexity and subtlety of its symptoms, necessitating specialized techniques and expertise.

Deep Learning (DL) approaches, particularly in image analysis and pattern recognition, are frequently utilized in the medical diagnosis domain. While DL applications are often employed for tuberculosis detection in human chest X-rays, there is a substantial gap in research focusing on bTB detection within animal products. This study aims to address this gap by proposing a Convolutional Neural Network (CNN) approach for detecting bTB in meat products. The dataset used in this research comprises images of bTB-infected and healthy cattle meat sourced from various organizations—such as anti-tuberculosis foundations—and veterinary publications. These images were carefully selected to ensure high quality, and comprehensive data augmentation techniques were applied to balance the dataset and enhance the model's learning capabilities. The resulting dataset was modeled using five different CNN architectures: ResNet-50, DarkNet-53, MobileNet-v2, GoogleNet, and EfficientNet-b0. Each model's performance was evaluated based on multiple metrics, including accuracy, precision, recall, and F1-score. The high accuracy rates achieved by these models underscore the potential of DL techniques to automate and improve bTB detection in meat products. Rapid and accurate identification of bTB-infected meat will significantly bolster food safety measures and reduce the risk of tuberculosis transmission to humans. Additionally, leveraging DL models helps minimize human error and provides more consistent, objective results with higher precision.

Keywords: deep learning, classification, bovine tuberculosis, meat products, Convolutional Neural Network, CNN, food safety, zoonotic diseases, *Mycobacterium bovis*

BÖLÜM 1. GİRİŞ

Tüberküloz, *Mycobacterium tuberculosis* bakterisinin (MTBC) neden olduğu, insanlarda genellikle akciğerleri etkileyen bulaşıcı bir hastalıktır. Bu bakteri, yavaş büyür ve hücre dışı/hücre içi koşullarda varlığını sürdürebilmektedir (World Health Organization, 2022). Ayrıca gizli faza geçebilmekte ve konak bağışıklık zayıf bir duruma düştüğünde tekrar üstel büyüme fazına dönebilmektedir. Buna karşılık, bTB ise *Mycobacterium bovis* (*M. bovis*) bakterisi nedeniyle özellikle sığırlarda görülen ve insanlara da bulaşabilen zoonotik bir hastalıktır (Olea-Popelka ve arkadaşları, 2017). Her iki hastalık da solunum yoluyla veya enfekte süt ve süt ürünlerinin tüketilmesiyle insanlara geçerek halk sağlığı açısından ciddi bir tehdit oluşturmaktadır (Ramos ve arkadaşları, 2015).

M. bovis, bir MTBC üyesi olup, sığırların yanı sıra keçiler, domuzlar, köpekler ve diğer memeli hayvanlarda da enfeksiyona yol açabilmektedir (Thoen ve arkadaşları, 2006). İnsanlara bulaşma genellikle pastörize edilmemiş süt ve süt ürünlerinin tüketilmesi, kontamine etlerin yenmesi veya enfekte hayvanlarla doğrudan temas sonucu gerçekleşmektedir. Ayrıca, enfekte hayvanların solunum yoluyla bakteriyi yayması, çiftlik çalışanları ve hayvancılıkla uğraşan kişiler için ek bir risk oluşturmaktadır (Müller ve arkadaşları, 2013).

Küresel ölçekte, yaklaşık 50 milyondan fazla sığırın sığır tüberkülozu (bTB) ile enfekte olduğu tahmin edilmektedir (Cousins, 2001). Bu durum, özellikle gelişmekte olan ülkelerde hem hayvan sağlığı hem de gıda güvenliği açısından büyük bir tehdit yaratmaktadır. bTB'nin kontrol altına alınamaması, hayvansal gıda ürünleri aracılığıyla insanlarda enfeksiyon riskini artırmakta ve zoonotik hastalıkların yayılımını hızlandırmaktadır. Bu nedenle, hastalığın yayılmasını önlemek için pastörizasyon, hayvan sağlığı taramaları, aşılama programları ve enfekte hayvanların erken tespiti gibi önlemler büyük önem taşımaktadır (Schiller ve arkadaşları, 2010).

Hayvansal ürünlerde bTB tespiti, halk sağlığının korunması açısından büyük önem taşımaktadır. Ancak, geleneksel teşhis yöntemleri genellikle insan faktörüne dayalı olduğu için zaman alıcı, maliyetli ve hata yapmaya daha yatkındır (Ramos ve arkadaşları, 2015). Bu noktada, derin öğrenme (DL) yöntemleri, özellikle tıbbi teşhis alanında önemli bir alternatif olarak öne çıkmaktadır (Litjens ve arkadaşları, 2017). DL, büyük veri kümelerinin analiz ederek karmaşık desenleri tanımlayabilen, insan beyninin öğrenme biçimini taklit eden bir yapay zeka yöntemidir. Bu yöntemler tıbbi teşhislerde röntgen, tomografi veya mikroskopik görüntü gibi verileri analiz edilmesi ile hastalıkların yüksek doğrulukla tespit edilebilmesine olanak sağlayabilmektedir. Tıbbi teşhislerde derin öğrenme yöntemlerinin kullanıldığı birçok araştırma mevcuttur (Litjens ve arkadaşları, 2017). Bu çalışmalar, özellikle görüntü işleme ve veri analizi alanlarında derin öğrenmenin sağladığı yüksek doğruluk oranlarıyla dikkat çekmektedir. Derin öğrenmedeki ilerlemelerle birlikte, evrimsel sinir ağları (CNN), görüntü tabanlı sınıflandırma ve tanıma problemlerinde üstün performans elde ederek geleneksel tanıma algoritmalarını sürekli olarak geride bırakmıştır (Guo ve diğerleri, 2020). Verinin doğal özelliklerinden otomatik olarak faydalı özellikler çıkartma yeteneği, evrimsel sinir ağları karmaşık tıbbi sorunların çözümünde ilk tercih haline getirmiştir. Araştırmacılar, CNN modellerini genellikle tüberküloz hastalığının insan üzerindeki etkinliğini göstermede sıklıkla tercih etmişlerdir (Anthimopoulos ve diğerleri, 2016; Lakhani ve Sundaram, 2017; Rajpurkar ve diğerleri, 2018; Pasa ve diğerleri, 2019; Lopez-Garnier ve diğerleri, 2019). Ancak, hayvansal etlerde bulunan bTB bakterisi (*Mycobacterium bovis*) teşhisinde bu algoritmaların başarısını inceleyen herhangi bir çalışma bulunmamaktadır.

Bu çalışma, bTB teşhisinde derin öğrenme tabanlı CNN algoritmasının uygulanabilirliğini araştırmaktadır. Bu kapsamda, bTB ile enfekte olmuş bakterili ve enfekte olmamış sağlıklı sığır etlerinin görüntülerinden oluşan geniş bir veri seti oluşturulup hayvansal etlerdeki bTB bakterisinin teşhisi için kullanılmıştır. Teşhis, derin öğrenme yöntemlerinden görüntü tabanlı modellerde başarılı olan CNN modelleri kullanılarak yapılmıştır. Bu kapsamda, ResNet-50, DarkNet-53, MobileNet-v2, GoogleNet ve EfficientNet-b0 gibi beş farklı CNN modeli ile çalışılmıştır. Modellerin eğitim ve test süreçleri, % 70-30 oranında eğitim-test bölmesi kullanılarak gerçekleştirilmiş ve farklı optimizasyon algoritmaları (Adam, RmsProp ve Sgdm) ile

parametre ayarlamaları yapılmıştır. Çalışma, çeşitli CNN modellerinin bTB tespitindeki etkinliğinin kapsamlı bir şekilde değerlendirilmesi ve bu modellerin gerçek uygulamalarda kullanılabilirliğinin gösterilmesi açısından özgün bir değer taşımaktadır. Çalışma sonunda her bir modelin öğrenme performansı doğruluk, kesinlik, duyarlılık ve F1 skoru gibi çeşitli metrikler kullanılarak değerlendirilmiştir.



BÖLÜM 2. LİTERATÜR ÖZETİ

Bu bölümde hayvansal gıdalarda tüberkülozun tespit edilmesi için kullanılan mevcut yöntemler ve bu yöntemlerin derin öğrenme teknikleri ile entegrasyonu literatür çerçevesinde ele alınmıştır. İncelenen literatür çalışmaları üç temel başlık altında toplanmıştır: Hayvansal gıdalarda geleneksel tüberküloz tespit yöntemleri, derin öğrenme tabanlı tüberküloz tespiti ve hayvansal gıdalarda tüberküloz tespiti için derin öğrenme uygulamaları.

2.1. Hayvansal Gıdalarda Geleneksel Tüberküloz Tespit Yöntemleri

Hayvansal kaynaklı gıdalarda tüberkülozun teşhisi için geleneksel yöntemler uzun yıllardır kullanılmakta olup mikrobiyolojik, immünolojik ve moleküler tekniklere dayanmaktadır. Bu yöntemlerin temel amacı, zoonotik potansiyele sahip olan *Mycobacterium bovis*'in varlığını erken aşamada ve güvenilir şekilde belirleyebilmektir (Domingo ve arkadaşları, 2014; Good ve Duignan, 2017).

Geleneksel yöntemler arasında en yaygın kullanılan tekniklerden biri, Single Intradermal Comparative Cervical Tuberculin Test (SICCT) olarak bilinen deri testidir. Bu testte, hayvanın bağışıklık sistemi tarafından *Mycobacterium bovis* antijenlerine karşı oluşturulan gecikmiş tipte hipersensitivite reaksiyonu ölçülmektedir. SICCT testi yüksek özgüllüğe sahip olsa da duyarlılık açısından bazı sınırlamalara sahiptir; bu nedenle enfekte hayvanların bir kısmının teşhis edilmesinde yetersiz kalabilmektedir (Casal ve arkadaşları, 2014; Bezos ve arkadaşları, 2014).

Mikrobiyolojik analizler arasında *Mycobacterium* türlerinin kültür yöntemiyle izolasyonu "altın standart" olarak kabul edilmektedir. Bu yöntemde enfekte olduğu düşünülen dokulardan alınan örnekler özel besiyerlerinde inkübe edilerek bakterinin üremesi beklenmektedir. Kültürleme yöntemi yüksek özgüllük sağlamakla birlikte, sonuçların elde edilmesi için yaklaşık 6 ila 8 haftalık uzun bir süre gerektirmektedir (Skuce ve arkadaşları, 2012; Corner ve arkadaşları, 2017). Ayrıca bu yöntemin

laboratuvar altyapısı bakımından yüksek standartlar gerektirmesi, uygulama alanını sınırlamaktadır.

Moleküler yöntemlerin gelişimiyle birlikte Polimeraz Zincir Reaksiyonu (*PCR*) gibi teknikler, geleneksel yöntemlere kıyasla daha hızlı ve spesifik sonuçlar sunmaktadır. *PCR* yöntemi, enfekte dokulardan veya hayvansal ürünlerden alınan DNA örneklerini kullanarak *Mycobacterium bovis* varlığını kısa sürede doğrulayabilmektedir (Taylor ve arkadaşları, 2007; Lorente-Leal ve arkadaşları, 2019). *PCR* tekniği, yüksek duyarlılık ve özgüllük oranlarına sahip olması nedeniyle geleneksel kültürlenme yöntemlerine önemli bir alternatif oluşturmaktadır.

İmmünolojik yaklaşımlar arasında ise gamma interferon testi (*IFN- γ* testi) öne çıkmaktadır. Bu testte kan örnekleri kullanılarak interferon gama üretimi ölçülmekte ve enfeksiyonun erken evrelerinde dahi teşhis mümkün hale gelmektedir (Schiller ve arkadaşları, 2010; Bezos ve arkadaşları, 2014). Gamma interferon testi genellikle deri testine yardımcı bir yöntem olarak kullanılarak tanı duyarlılığını artırmaktadır; ancak maliyetli olması ve laboratuvar koşullarına bağımlılığı nedeniyle yaygın kullanımı sınırlı kalmaktadır.

2.2. Derin Öğrenme Tabanlı Tüberküloz Tespiti

Son yıllarda derin öğrenme yöntemleri, tüberküloz teşhisinde önemli bir teknoloji olarak ön plana çıkmıştır. Özellikle görüntü işleme alanında kullanılan evrişimli sinir ağları (Convolutional Neural Networks, *CNN*), tüberküloz gibi heterojen enfeksiyonların teşhisinde yüksek doğruluk oranları sunmaktadır (Rahman ve arkadaşları, 2020; Capellán-Martín ve arkadaşları, 2023). *CNN* modelleri, büyük veri kümelerinden karmaşık örüntüleri öğrenebilme yeteneğine sahip olmaları nedeniyle tıbbi görüntüleme alanında sıklıkla tercih edilmektedir (Schiller ve arkadaşları, 2010; Lorente-Leal ve arkadaşları, 2019).

Tüberkülozun teşhisinde en yaygın kullanılan görüntüleme yöntemlerinden biri göğüs röntgeni (Chest X-ray, *CXR*) görüntüleridir. *CNN* tabanlı modeller, göğüs röntgeni görüntülerinin otomatik analizinde yüksek doğruluk oranlarına ulaşmaktadırlar. Rahman ve arkadaşları (2020), transfer öğrenme tekniklerini kullanarak göğüs röntgeni görüntülerinden tüberküloz teşhisinde %99.9 gibi oldukça yüksek bir doğruluk oranı elde etmişlerdir. Benzer şekilde Capellán-Martín ve arkadaşları (2023), düşük işlem gücü

gerektiren LightTBNet isimli bir CNN modeli geliştirmişlerdir. Bu modelin özellikle kaynakların sınırlı olduğu bölgelerde uygulanabilirliği yüksektir ve klinik kullanıma uygunluğu kanıtlanmıştır.

Son dönemde yapılan çalışmalar, derin öğrenme yöntemlerinin farklı modalitelerle birleştirilerek tanı performansının daha da artırılabilirliğini göstermektedir. Örneğin, multimodal yaklaşımlar kullanılarak göğüs radyografileri ile balgam kültür sonuçlarını tahmin eden modeller geliştirilmiş ve bu modellerin klinik ortamlarda başarılı sonuçlar verdiği bildirilmiştir (Kim ve arkadaşları, 2023). Ayrıca TSSG-CNN gibi semantik segmentasyon tabanlı CNN modelleri geliştirilerek hastalıkla ilişkili spesifik alanların belirlenmesi sağlanmakta ve böylece tanı doğruluğu artırılmaktadır (Mdpi, 2024).

Derin öğrenme algoritmalarının geliştirilmesinde veri setlerinin büyüklüğü ve kalitesi kritik önem taşımaktadır. Bu nedenle veri artırma yöntemleri sıklıkla kullanılmaktadır. Örneğin görüntü döndürme, yeniden boyutlandırma, kontrast sınırlamalı adaptif histogram eşitleme (CLAHE) ve gama düzeltmesi gibi ön işleme teknikleri kullanılarak veri çeşitliliği artırılmakta ve model performansı güçlendirilmektedir (PMC, 2024).

Sonuç olarak derin öğrenme tabanlı algoritmaların tüberküloz teşhisindeki etkinliği birçok çalışma tarafından kanıtlanmış olup geleneksel yöntemlere kıyasla daha hızlı, tutarlı ve hassas sonuçlar sunmaktadırlar. Ancak bu teknolojilerin klinik uygulamalarda yaygınlaşabilmesi için daha geniş çaplı veri setlerine ihtiyaç duyulmakta olup algoritmaların farklı klinik senaryolarda validasyonunun yapılması gerekmektedir (Nature, 2023; JMIR, 2023).

2.3. Hayvansal Gıdalarda Tüberküloz Tespiti için Derin Öğrenme Uygulamaları

Hayvansal gıdalarda tüberkülozun derin öğrenme yöntemleri ile tespit edilmesine yönelik çalışmalar henüz sınırlı sayıdadır. Ancak son dönemde gerçekleştirilen araştırmalar, bu alanda önemli bir potansiyel olduğunu ortaya koymaktadır. Özellikle hayvansal ürünlerin güvenilirliğini artırmak ve halk sağlığını korumak amacıyla, ileri görüntü işleme teknikleri ve yapay zekâ tabanlı yaklaşımların entegrasyonu giderek önem kazanmaktadır (Al-Sarayreh ve arkadaşları, 2022; Zhang ve arkadaşları, 2022).

Hayvansal ürünlerde tüberkülozun teşhisinde geleneksel yöntemlerin uzun analiz süreleri ve sınırlı duyarlılıkları göz önüne alındığında, derin öğrenme tabanlı yaklaşımlar önemli avantajlar sunmaktadır. Örneğin, mikroskobik doku görüntülerinin otomatik analizi için


CNN kullanılabilmektedir. CNN modelleri, enfekte dokulardaki mikroskobik düzeydeki patolojik deęişimleri otomatik olarak tanımlayarak teşhis sürecini hızlandırmakta ve doğruluęunu artırmaktadır (Liu ve arkadaşları, 2024). Ayrıca PCR gibi moleküler yöntemlerle elde edilen sonuçların doğrulanmasında da derin öğrenme algoritmaları tamamlayıcı rol oynayabilmektedir. Bu tür hibrit yaklaşımlar, teşhis süreçlerinde hata oranlarını azaltmakta ve testlerin güvenilirliğini yükseltmektedir (Lee ve arkadaşları, 2024).

Son dönemde gerçekleştirilen çalışmalarda, sürü düzeyindeki tüberküloz enfeksiyonlarının erken tahmini için makine öğrenimi algoritmaları başarıyla kullanılmıştır. Örneęin Banks ve arkadaşları (2024), Histogram-based Gradient Boosting Tree (HGBT) algoritmasını kullanarak sürü bazındaki tanısal duyarlılığı %16 oranında artırmışlardır. Bu yaklaşımda hayvan hareketleri, çevresel faktörler ve geçmiş test sonuçları gibi risk faktörleri entegre edilerek enfeksiyon riski daha doğru şekilde belirlenmiştir (Banks ve arkadaşları, 2024; EPIC Scotland, 2024).

Sonuç olarak hayvansal gıdalarda tüberküloz teşhisi için derin öğrenme uygulamaları henüz gelişmekte olan bir alan olup mevcut çalışmalar umut verici sonuçlar ortaya koymaktadır. Geleneksel yöntemlere kıyasla daha hızlı, daha hassas ve daha tutarlı sonuçlar sağlayan bu teknolojilerin yaygınlaşması için daha geniş çaplı veri setlerine ihtiyaç duyulmakta olup farklı koşullar altında validasyon çalışmaları yapılmalıdır.

BÖLÜM 3. MATERYAL VE METOT

Bu çalışma kapsamında, et görüntüleri kullanılarak bTB ile enfekte olmuş etleri tespit etmek için DL modelleri kullanılmıştır. Önerilen metodolojinin mimarisi Şekil 3.1’ de gösterilmektedir.



Şekil 3.1 Önerilen metodolojinin mimarisi

3.1. Veri Kümesi

Bu bölümde çalışmada kullanılan veri setinin kaynakları, boyutları, çeşitliliği ve veri hazırlık süreçleri olarak incelenmektedir. Veri seti, çalışmanın temel unsurlarından biri olup, modelin başarısını doğrudan etkileyen önemli bir faktördür (László Bognár ve Tibor Fauszt, 2022).

Çalışmada kullanılan veri kümesi, sığır etinin görsel özelliklerine dayanarak bTB ile enfekte olmuş ve sağlıklı olarak iki kategoriye ayrılmış toplam 379 görüntüden oluşmaktadır. Bu görüntülerin 324 tanesi sağlıklı et, 55 tanesi ise bTB ile enfekte olmuş et örneklerine aittir. Veri kümesi mevcut bir kaynaktan alınmamış tamamen sıfırdan

oluşturulmuştur. Bu durum veri kümesinin özgünlüğünü ve çalışmanın literatüre katkısını artırmaktadır.

Sağlıklı et örnekleri özellikle gıda ve hayvancılıkla ilgili güvenilir web sitelerinden toplanmıştır. Görüntülerin toplanmasında, "sağlıklı sığır eti", "kırmızı et", "sağlıklı et", "hayvansal et", "temiz kırmızı et" gibi çeşitli anahtar kelimeler kullanılmış ve bu aramalar için özel eklentilerden faydalanılmıştır. Bu sayede, farklı kaynaklardan çeşitli görseller elde edilmiştir.

bTB ile enfekte olan et örnekleri daha spesifik ve kısıtlı kaynaklardan toplanmıştır. Görüntüler, tüberkülozla mücadele eden vakıfların veri tabanlarından, tıbbi literatürden ve veterinerlik sağlık yayınlarından temin edilmiştir. Bu tür verilerin seçimi sırasında, bilimsel doğruluk ve görsel kalite ön planda tutulmuştur. Görüntüler, farklı kaynaklardan sağlanarak veri kümesinin çeşitliliği artırılmış ve çalışmanın genellenebilirliği güçlendirilmiştir.

Veri toplama sürecinde kaliteye büyük önem verilmiştir. Gürültü, bozulma, bulanıklık, eksik ışıklandırma ya da uygun olmayan açılar gibi kusurlara sahip görüntüler veri kümesinden çıkarılmıştır. Sadece net, odaklanmış ve tanımlayıcı özellikler içeren görseller çalışmaya dahil edilmiştir. Veri setindeki sağlıklı ve bTB ile enfekte sınıflarına ait örnek görüntüler şekil 3.2’de verilmiştir.



Şekil 3.2 Sağlıklı (solda) ve bTB ile enfekte (sağda) sığır eti görüntü örnekleri

3.1.1. Veri ön işleme süreci

Bu bölümde, çalışmada kullanılan veri setinin ön işleme ve artırma adımları detaylıca ele alınmaktadır. Toplanan ham görüntüler üzerinde kapsamlı bir hazırlık süreci uygulanmış olup, bu süreç veri setinin model eğitimi için uygun hale getirilmesini sağlamıştır. İlk aşamada, tüm görüntüler standart bir boyut ve çözünürlük formatına dönüştürülmüştür. Bu adım, farklı kaynaklardan gelen görüntüler arasındaki uyumsuzlukları ortadan kaldırmak açısından kritik öneme sahiptir. Eğitim ve test süreçlerinde veri setinin dengeli olmasını sağlamak amacıyla veri artırma teknikleri kullanılmıştır. Özellikle sağlıklı ve

bTB ile enfekte olmuş örnekler arasındaki dengesizliği gidermek için döndürme, yakınlaştırma ve yansıma gibi yöntemler uygulanmıştır. Bu teknikler, modelin aşırı öğrenme sorununa karşı daha dayanıklı olmasına yardımcı olmuştur. Ayrıca, veri setindeki her bir görüntü ilgili kategorilere ayrılarak sınıflandırılmıştır.

Sağlıklı et örnekleri genellikle homojen bir yüzey yapısı ve tipik kırmızı renk tonları sergilerken bTB ile enfekte olan etler; düzensiz yapılar, renk farklılıkları ve bazı durumlarda lezyonlara sahip olabilir (Jochen Weiss ve arkadaşları, 2010). Bu özellikler sınıflandırma sürecinde CNN modellerinin başarılı bir şekilde öğrenebilmesi için önemli kriterlerdir. Sonuç olarak bu veri kümesi, hem çeşitliliği hem de kaliteli yapısı ile çalışmanın hedeflerini destekleyecek şekilde hazırlanmıştır.

Veri artırma teknikleri derin öğrenme modellerinin performansını artırmak için kullanılan yöntemlerdendir (Cherry Khosla ve Baljit Singh Saini, 2020). Özellikle sınıflar arasındaki dengesiz veri dağılımlarını dengelemek ve modelin genelleme kapasitesini artırmak için uygulanmaktadır (Sitara Afzal ve arkadaşları, 2019).


Çalışmanın başlangıç aşamasında veri kümesinde bTB ile enfekte olan ve sağlıklı et örnekleri arasında belirgin bir dengesizlik bulunmaktaydı. Bu dengesizliğin modelin öğrenme kapasitesini olumsuz etkilememesi için az temsil edilen sınıftaki görüntüler (hastalıklı) çoğaltılmış ve her iki sınıfın eşit sayıda görüntüye sahip olması sağlanmıştır. Bu işlem sonucunda veri kümesi her bir sınıf için 1000 görüntü olacak şekilde dengelenmiş ve toplamda 2000 görüntüye ulaşmıştır.

Çalışmada kullanılan görüntüler, modelin gereksinimlerine uygun hale gelmesi için çeşitli işlemlerden geçirilmiştir. Tüm görüntüler transfer öğrenme yöntemleriyle uyumlu olması için 224x224 piksel boyutunda yeniden boyutlandırılmıştır (Neelam Sharma ve arkadaşları, 2023). Bu adım, farklı çözünürlük ve boyutlara sahip ham görüntülerin bir standart haline getirilmesini sağlamıştır.

Derin öğrenme modellerinin başarısının, eğitim verisinin kalitesi ve dengesi ile doğrudan ilişkisi bulunmaktadır. Ancak veri kümesinde sınıflar arasında dengesizlik olması durumunda modelin öğrenme sürecinde belirli bir sınıfa öncelik vermesi (*bias*) olasıdır (Hagendorf ve arkadaşları, 2024). Bu sorunu çözmek için geleneksel veri artırma teknikleri uygulanmıştır. Çalışmada kullanılan geleneksel veri artırma yöntemleri şunlardır:

- Parlaklık Ayarlaması: Görüntülerin parlaklığı değiştirilerek, farklı ışık koşullarında modelin genelleme yeteneği artırılmıştır (Zeshan Hussain ve arkadaşları, 2017).
- Simetri ve Yansımalar: Görüntüler yatay olarak yansıtılarak veri kümesinin çeşitliliği artırılmıştır (Roger Grosse ve arkadaşları, 2009).
- Yakınlaştırma: Görüntüler belirli oranlarda yakınlaştırılarak, modelin farklı ölçeklerdeki özellikleri öğrenmesi sağlanmıştır (Nanne van Noord ve Eric Postma, 2017).
- Rastgele Döndürme: Görüntüler rastgele açılarla döndürülerek modelin yönelime duyarlılığı azaltılmıştır (Stephane Allaire ve arkadaşları, 2008).

Şekil 3.3’ te, orijinal görsel ile veri artırma tekniklerini sonucu görselleştirilmiş örnekler verilmiştir.

Orijinal Görsel	Düşük Parlaklık	Düşük Parlaklık x eks. Simetrisi	Düşük Parlaklık x eks. Simetrisi Uzaklaştırma	x eks. Simetrisi Yakınlaştırma	Açı Değişimi
					

Şekil 3.3 Kullanılan veri artırma teknikleri örnekleri

Veri kümesinde bTB ile enfekte olan ve sağlıklı et örnekleri arasındaki dengesizliğin modelin öğrenme kapasitesini olumsuz etkilememesi için hastalıklı görüntüler çoğaltılmıştır. Bu işlem sonucunda veri kümesi her bir sınıf için 1000 görüntü olacak şekilde dengelenmiştir.

Geleneksel veri çoğaltmanın yanı sıra üretici çekişmeli ağlar (*Generative Adversarial Networks*) (GAN) ile veri çoğaltma ile veri kümesindeki görüntüler artırılmıştır. GAN, üretici (*generator*) ve (*discriminator*) olmak üzere iki ayrı sinir ağından oluşan bir yapıdır. Üretici, gerçek veri dağılımını taklit ederek sentetik veri üretmektedir. Ayırt edici ise gerçek veri ile üretici tarafından oluşturulan sentetik veriyi birbirinden ayırmaya çalışmaktadır. Bu iki ağ, birbirine karşı rekabet içinde eğitilmekte olup, üretici ağın daha gerçekçi veriler üretmesi ve ayırt edici ağın ise bu sentetik verileri daha iyi tespit etmesi sağlanmaktadır. Böylece, eğitim süreci bir oyun kuramı çerçevesinde dengeye ulaşmakta

ve üretici ağ, ayırt ediciyi yanıltabilecek derecede gerçekçi veriler üretmektedir. Geleneksel veri artırma tekniklerinin aksine GAN ile elde edilen sentetik veriler daha yüksek çeşitlilik ve gerçekçilik sunmakta olup bu da modelin genelleme yeteneğini artırmakta ve aşırı öğrenme riskini azaltmaktadır.

3.2. Evrişimsel Sinir Ağı

3.2.1. Evrişimsel sinir ağlarına giriş

CNN, yapay sinir ağlarının özel bir türü olarak, özellikle görüntü işleme ve bilgisayarlı görü alanlarında devrim niteliğinde bir etki yaratmıştır (Hewa Majeed Zangana ve arkadaşları, 2024). CNN'in kökeni 1980'li yıllarda Yann LeCun tarafından geliştirilen LeNet mimarisine kadar uzanmaktadır (James L. Crowley, 2021). LeNet, el yazısı rakamların tanınması gibi görevlerde başarılı olmuş ve CNN'lerin temel prensiplerini ortaya koymuştur. 2012 yılında AlexNet'in ImageNet yarışmasında elde ettiği başarı, CNN'lerin popülerliğini artırmış ve derin öğrenme alanında bir dönüm noktası olmuştur (Charu C. Aggarwal, 2023). AlexNet'ten sonra VGGNet, ResNet, Inception ve EfficientNet gibi daha gelişmiş mimariler ortaya çıkmış ve evrişimli sinir ağlarının performansını daha da artırmıştır.

CNN'lerin evrimi, büyük veri setlerinin ve yüksek performanslı hesaplama kaynaklarının (GPU'lar ve TPU'lar) kullanılabilir hale gelmesiyle hız kazanmıştır. Bu gelişmeler, evrişimli sinir ağlarının daha derin ve karmaşık mimarilerle eğitilmesine olanak sağlamış ve görüntü sınıflandırma, nesne algılama, segmentasyon gibi görevlerde insan seviyesine yakın performanslar elde edilmesini mümkün kılmıştır (Gu ve arkadaşları, 2019).

CNN, geleneksel sinir ağlarından farklı olarak, özellikle görüntü verileri için optimize edilmiş katmanlardan oluşur. Bu katmanlar, görüntülerdeki uzamsal hiyerarşik özellikleri otomatik olarak öğrenmeyi sağlar. CNN'lerin temel bileşenleri Konvolüsyonel Katmanlar, havuzlama katmanları ve tam bağlı katmanlardan oluşmaktadır (LeCun ve arkadaşları, 1998).

Konvolüsyonel katmanlar, CNN'lerin en önemli bileşenidir. Bu katmanlar, giriş görüntüsü üzerinde filtreler kullanarak yerel özellikleri çıkarmaktadır (Yu Han Liu 2018). Her filtre, görüntünün belirli bir bölgesindeki özellikleri (örneğin, kenarlar, dokular) tespit etmek için kullanılmaktadır. Konvolüsyon işlemi, parametre paylaşımı sayesinde

hesaplama verimliliğini arttırırken modelin uzamsal hiyerarşik özellikleri öğrenmesini sağlamaktadır.

Havuzlama katmanları, konvolüsyonel katmanların çıkışlarını alt örnekleyerek özellik haritalarının boyutunu küçültmektedir. Bu işlem, modelin hesaplama karmaşıklığını azaltırken önemli bilgileri korumaktadır. En yaygın kullanılan havuzlama yöntemleri, maksimum havuzlama ve ortalama havuzlamadır (Florentin Bieder ve arkadaşları, 2014).

Tam bağlı katmanlar, CNN'lerin son kısmında yer almakta olup, özellik haritalarını sınıflandırma veya regresyon görevleri için kullanılabilir bir forma dönüştürmektedir. Bu katmanlar, geleneksel sinir ağlarındaki gibi her bir nöronun bir sonraki katmandaki tüm nöronlara bağlı olduğu bir yapıya sahiptir.

CNN, geleneksel sinir ağlarıyla karşılaştırıldığında özellikle görüntü verileri için daha uygun bir mimari sunmaktadır. CNN ise konvolüsyonel katmanlar sayesinde yerel özellikleri çıkarmakta ve parametre paylaşımı ile hesaplama verimliliğini artırmaktadır. Ayrıca, havuzlama katmanları sayesinde görüntülerin boyutunu küçülterek modelin daha hızlı eğitilmesini sağlamaktadır. Geleneksel sinir ağları, genellikle düzleştirilmiş (*flattened*) veriler üzerinde çalışırken, CNN görüntülerin uzamsal yapısını korumakta ve bu yapıyı kullanarak daha etkili özellik çıkarımı gerçekleştirmektedir (Yushi Chen ve arkadaşları, 2016). Bu nedenle, CNN özellikle görüntü sınıflandırma, nesne algılama ve segmentasyon gibi görevlerde geleneksel sinir ağlarına kıyasla çok daha başarılı sonuçlar elde etmektedir (Anamika Dhillon ve Gyanendra K. Verma, 2020).

3.2.2. Evrimsel sinir ağlarının çeşitleri

CNN, zaman içinde çeşitli yeniliklerle geliştirilmiş ve farklı ihtiyaçlara yönelik optimize edilmiş mimariler ortaya çıkmıştır. Bu mimariler, derin öğrenme alanında önemli ilerlemeler kaydetmiş ve görüntü işleme görevlerinde yüksek performans sunmuştur (A. Sai Bharadwaj Reddy ve D. Sujitha Juliet, 2019)

3.2.2.1. ResNet-50

Residual Network, 50 katmanlı (ResNet-50), görüntü analizi ve sınıflandırma alanlarında en çok kullanılan ve derin öğrenme modelleri arasında dikkat çeken bir CNN mimarisidir (S Mascarenhas ve M Agarwal, 2021). ResNet ailesinin bir üyesi olan bu mimari, derin

sinir ağlarının eğitiminde sıkça karşılaşılan problemleri ele almayı amaçlayan yenilikçi bir yapı sunmaktadır (Ke Zhang ve arkadaşları). Özellikle gradyan kaybolması (*vanishing gradient*) ve gradyan patlaması (*exploding gradient*) gibi sorunları çözüme kavuşturarak daha derin ağların daha verimli ve başarılı bir şekilde eğitilmesine olanak tanmaktadır (Lokesh Borawar ve Ravinder Kaur, 2023). ResNet-50'nin temel fark yaratan özelliği, rezidüel bağlantılar (*residual connections*) veya kısaca atlamalı bağlantılar (*skip connections*) adı verilen bir mekanizmayı içermesidir (Andreas Veit ve arkadaşları, 2016). Bu bağlantılar, giriş sinyalinin bir katmanın çıkışına taşıyarak gradyanın ağ boyunca daha kolay akmasına olanak tanımaktadır. Bu durum, hem ağın daha derinleştirilmesini hem de modelin performansının korunmasını sağlamaktadır (Mingxing Tan ve Quoc V. Le, 2019). Rezidüel bağlantılar, ağın sadece öğrenmesi gereken farkı (*residual*) öğrenmesine yardımcı olarak hesaplama yükünü azaltmakla kalmaz bunun yanında daha yüksek doğruluk oranları elde edilmesine katkı sağlayarak performansı arttırmaktadır. Örneğin, bir katman girişine x denildiğinde, standart bir ağ $F(x)$ fonksiyonunu öğrenirken, ResNet bu giriş ile birlikte çıkışın farkını $F(x)+x$ olarak öğrenmektedir. Bu yöntem, eğitim sırasında ortaya çıkan zorlukları büyük ölçüde hafifleterek çok derin ağlarda bile yüksek doğruluk elde edilmesini sağlamaktadır.

ResNet-50, 50 katmandan oluşan derin bir yapıdadır ve bu katmanlar arasında çok sayıda konvolüsyonel, havuzlama ve tam bağlantılı (*fully connected*) katman yer almaktadır. (Gao Huang ve arkadaşları, 2022). Özellikle, 3×3 boyutunda konvolüsyon çekirdekleri ve farklı aşamalarda uygulanan aşağı örnekleme (*downsampling*) işlemleri ile çeşitli ölçeklerdeki özellikleri çıkarma yeteneği sunmaktadır (Kaiming He ve arkadaşları, 2015). Model, genellikle He başlatıcısı (*He Initialization*) yöntemiyle başlatılır ve toplu normalizasyon gibi tekniklerle eğitimi kolaylaştırılır. Bununla birlikte, her 3 katmanda bir kullanılan rezidüel bloklar, ağın derinliği arttıkça bile performansının korunmasını sağlamaktadır.


ResNet-50'nin başlangıç katmanında 7×7 boyutunda bir konvolüsyon katmanı bulunmakta olup, bunu takip eden bir maksimum havuzlama (*max pooling*) katmanı yer almaktadır. Ara katmanlarda 3, 4, 6 ve 3 artık bloktan oluşan dört aşama bulunmaktadır. Her aşamada evrişim işlemi farklı derinliklerde gerçekleştirilmektedir. Modelin sonunda Global ortalama havuzlama (*global average pooling*) katmanı ile tam bağlı (*fully connected*) bir katman mevcuttur.

ResNet-50 yaklaşık 25 milyon öğrenilebilir parametre içermekte ve bu da mimarinin yüksek karmaşıklığa sahip olduğunu ancak bu karmaşıklığın güçlü sonuçlar üretmek için optimize edildiğini göstermektedir (R. Anand ve arkadaşları, 2023).

Şekil 3.4’ de ResNet-50 mimarisinin yapısı ve katmanlar arasındaki veri akışı gösterilmektedir. ResNet-50, toplamda 50 katmandan oluşan bir CNN mimarisidir. Görsel, bu mimarideki temel katmanları, işlemleri ve boyut değişikliklerini özetlemektedir.

Şekil 7, ResNet-50’nin girişten (224x224 boyutunda bir görüntü) başlayarak nasıl özellik çıkardığını ve sonunda 100 sınıf için bir tahmin ürettiğini göstermektedir. Her katman, boyutları küçültürken daha karmaşık ve soyut özellikler öğrenmektedir. Rezidüel bağlantılar, bu süreci destekleyerek daha derin ağların eğitilmesine olanak tanımaktadır. ResNet-50, bu yapısı sayesinde görüntü sınıflandırma, nesne algılama ve birçok diğer görevde yüksek doğrulukla sonuçlar elde etmektedir. Bu mimari, toplamda 50 katmandan oluştuğundan hem derin hem de efektif bir CNN mimarisi olarak kabul edilmektedir.

Bu yapı sayesinde ResNet-50, sadece görüntü sınıflandırmada değil, aynı zamanda nesne algılama, semantik segmentasyon ve medikal görüntü analizi gibi birçok farklı alanda yüksek doğruluk oranlarına ulaşmıştır (Hang Yu ve arkadaşları, 2021).



Şekil 3.4 ResNet-50 mimari yapısı

Bu mimari, özellikle yüksek doğruluk gerektiren görevlerde çok geniş bir uygulama alanına sahiptir. ResNet-50’nin bu yenilikçi yapısı, sadece teorik olarak değil, pratikte de birçok alanda başarıyla uygulanmaktadır.

Görüntü sınıflandırma, nesne algılama, semantik segmentasyon, yüz tanıma ve medikal görüntü analizi gibi birçok alanda ResNet-50’nin başarısından söz etmek mümkündür (Geert Litjens ve arkadaşları, 2017). Özellikle medikal görüntü analizinde, rezidüel bağlantıların sağladığı avantajlar sayesinde ResNet-50, MRI ve röntgen görüntülerindeki

anormalliklerin tespitinde yüksek doğruluk oranlarıyla öne çıkmakta ve bu da doktorların teşhis süreçlerini önemli ölçüde hızlandırmaktadır (Yang Zhang ve arkadaşları, 2023). Benzer şekilde, otonom sürüş sistemlerinde bu mimari, karmaşık trafik sahnelerindeki nesnelerin tanımlanmasına yardımcı olmaktadır. ResNet-50'nin başarısı, yalnızca yüksek doğruluk oranlarıyla sınırlı değildir; aynı zamanda diğer derin öğrenme modellerine kıyasla daha düşük hata oranlarıyla da öne çıkmaktadır. ResNet-50 ve onun varyantları, derin öğrenme alanında önemli bir dönüm noktası olarak kabul edilmekte ve gelecekteki araştırmalara ilham kaynağı olmaya devam etmektedir.

3.2.2.2. DarkNet-53

DarkNet-53, derin öğrenme tabanlı nesne algılama ve sınıflandırma problemlerinde sıklıkla kullanılan hafif ancak güçlü bir CNN mimarisidir. YOLOv3 (*You Only Look Once Version 3*) nesne algılama sisteminin çekirdek modeli olarak tasarlanan DarkNet-53, özellikle gerçek zamanlı uygulamalar için optimize edilmiş yapısıyla dikkat çekmektedir. Bu mimari, yüksek doğruluk ve hız sunarken sınırlı hesaplama kaynaklarıyla dahi etkili sonuçlar üretebilmektedir.

DarkNet-53, 53 katmanlı bir CNN mimarisidir ve ağıın her katmanında yer alan optimize edilmiş evrimsel yapılar sayesinde verimli bir şekilde çalışmaktadır. Bu mimari, özellikle nesne algılama görevlerinde yüksek doğruluk sunarken hesaplama gereksinimlerini düşürmeyi amaçlamaktadır. Yapısal olarak DarkNet-53, ResNet mimarisine benzer şekilde "artık bloklar" (*residual blocks*) kullanmaktadır. Bu bloklar, girdilerin doğrudan çıktıya aktarılmasına olanak tanıyarak derin ağlarda karşılaşılan gradyan kaybolması sorununu önlemektedir (G. Divya Deepak ve arkadaşları, 2024) (Shuang Cong ve Yang Zhou, 2023).

DarkNet-53, çoğunlukla 3x3 ve 1x1 evrim filtrelerinden oluşan katmanlar içermektedir. 3x3 filtreler geniş özellikler öğrenirken, 1x1 filtreler hesaplama maliyetini azaltarak ağı derinleştirmektedir. ResNet-50'ye göre daha az parametre içermesine rağmen, DarkNet-53 doğruluk oranlarını daha hızlı sunmaktadır. Bu özellik, gerçek zamanlı uygulamalarda büyük bir avantaj sağlamaktadır.

Şekil 3.5'te yer alan tablo, DarkNet-53 mimarisinin katmanlarını ve bu katmanlarda gerçekleştirilen işlemleri detaylı bir şekilde göstermektedir. Tablo, modelin farklı aşamalarındaki konvolüsyonel katmanlar, filtre sayıları, filtre boyutları ve çıktı boyutları

hakkında bilgi vermektedir. Bu yapı, DarkNet-53'ün nasıl özellik haritaları (feature maps) oluşturduğunu ve bu haritaların boyutlarının nasıl değiştiğini açık bir şekilde ortaya koymaktadır.

Tablonun ilk satırında, 3x3 boyutunda 32 filtre içeren bir konvolüsyonel katman yer almaktadır. Bu katman 256x256 boyutunda bir çıktı üretmektedir. Ardından, 3x3 boyutunda 64 filtre içeren ve adım boyutu (stride) 2 olan bir konvolüsyonel katman gelmektedir. Bu katman, çıktı boyutunu 128x128'e düşürmektedir. Bu tür adım boyutu kullanımı, özellik haritalarının boyutlarını küçülterek hesaplama maliyetini azaltmaktadır.

Tablonun devamında, 1x1 boyutunda filtreler içeren konvolüsyonel katmanlar görülmektedir. Bu katmanlar, özellik haritalarının derinliğini artırmakta veya azaltmakta ve hesaplama karmaşıklığını düşürmektedir. Bu tür katmanlar, modelin daha verimli çalışmasını sağlamaktadır.

Tablonun ortalarında yer alan artık bloklar, girdilerin doğrudan çıktıya aktarılmasına olanak tanıyarak yukarıda bahsedilen gradyan kaybolması sorununu önlemektedir. Örneğin, 3x3 boyutunda 64 filtre içeren bir konvolüsyonel katman, 128x128 boyutunda bir çıktı üretmekte ve bu çıktı, artık bloklar sayesinde bir sonraki katmana aktarılmaktadır. Bu yapı, modelin derinliği arttıkça performansının korunmasını sağlamaktadır.

Tablonun sonlarına doğru, 3x3 boyutunda 1024 filtre içeren konvolüsyonel katman, çıktı boyutunu 8x8'e düşürmektedir. Ardından, global ortalama havuzlama (*global average pooling*) katmanı gelmektedir. Bu katman, özellik haritalarının boyutlarını 1x1'e indirerek modelin çıktısını hazırlamaktadır. Son olarak, tam bağlı (*fully connected*) bir katman ve softmax aktivasyon fonksiyonu kullanılarak modelin çıktısı üretilmektedir.

Bu tablo, DarkNet-53 mimarisinin hem genişlik (filtre sayıları) hem de derinlik (katman sayıları) açısından iyi optimize edildiğini göstermektedir. Model, büyük veri setlerinde yüksek doğrulukla çalışabilecek şekilde tasarlanmıştır. Bu yapı, özellikle gerçek zamanlı nesne tanıma sistemlerinde yaygın olarak kullanılmaktadır. (Joseph Remon ve Ali Farhadi, 2018)

	TİP	FİLTRE	BOYUT	ÇIKTI
	Evrişimsel	32	3x3	256x256
	Evrişimsel	64	3x3/2	128x128
1x	Evrişimsel	32	1x1	
	Evrişimsel	64	3x3	
	Artık			128x128
	Evrişimsel	128	3x3/2	64x64
2x	Evrişimsel	64	1x1	
	Evrişimsel	128	3x3	
	Artık			64x64
	Evrişimsel	256	3x3/2	32x32
8x	Evrişimsel	128	1x1	
	Evrişimsel	256	3x3	
	Artık			32x32
	Evrişimsel	512	3x3/2	16x16
8x	Evrişimsel	256	1x1	
	Evrişimsel	512	3x3	
	Artık			16x16
	Evrişimsel	1024	3x3/2	8x8
4x	Evrişimsel	512	1x1	
	Evrişimsel	1024	3x3	
	Artık			8x8
	Ort. Havuzlama Bağlı Softmax		Global 1000	

Şekil 3.5 DarkNet-53 mimari yapısı

3.2.2.3. MobileNet-v2

MobileNet-v2, mobil cihazlar ve gömülü sistemler gibi sınırlı donanım kaynaklarına sahip platformlar için özel olarak geliştirilmiş, hafif fakat yüksek performanslı bir CNN mimarisidir. Bu model, görüntü sınıflandırma, nesne tanıma ve semantik segmentasyon gibi çeşitli bilgisayarla görme görevlerine yönelik optimize edilmiştir ve düşük hesaplama gereksinimleri ile yüksek doğruluk oranını bir arada sunmaktadır. Bu nitelikleri sayesinde, yalnızca mobil cihazlarda değil, aynı zamanda drone, robotik ve diğer Nesnelerin İnterneti (IoT) tabanlı uygulamalarda da yaygın olarak kullanılmaktadır.

MobileNet-v2'nin en önemli yeniliklerinden biri, Kanal Ayrılabilir Evrişim (*depthwise separable convolution*) mimarisini kullanmasıdır. Bu teknik, geleneksel evrişim işlemini Kanal Ayrılabilir Evrişim ve Noktasal Evrişim (*Pointwise Convolution*) olmak üzere iki parçaya ayırmaktadır (Francois Chollet, 2017) Depthwise Convolution'da her kanal üzerinde ayrı ayrı evrişim uygulanırken, Noktasal Evrişim'de 1x1 filtreler kullanılarak kanallar arasındaki bağlantılar öğrenilmektedir. Bu yöntem, parametre ve işlem maliyetini önemli ölçüde azaltırken doğruluk kaybını minimumda tutmaktadır (Kamal KC ve arkadaşları, 2019).


MobileNet-v2'nin dikkat çeken bir diğer özelliği, Ters Çevrilmiş Artık Blok (*inverted residual block*) yapısını kullanmasıdır. Bu yapı, düşük hesaplama maliyetinde çalışırken daha karmaşık özellikleri öğrenme kapasitesini artırmakta ve gradyan kaybolması gibi sorunları önlemektedir. Ters Çevrilmiş Artık Bloklar'da, önce bir genişleme faktörü (t) ile giriş özellik haritası genişletilmekte, ardından depthwise convolution ile özellik çıkarımı yapılmakta ve en son 1x1 sıkıştırma evrişimi ile orijinal boyuta geri dönülmektedir. Bu ters çevrilmiş yapı, modeli daha hafif hale getirirken doğruluk kaybını önlemektedir.

MobileNet-v2, geleneksel ReLU yerine $\text{ReLU6}(x) = \min(\max(x, 0), 6)$ fonksiyonunu kullanmaktadır. Bu aktivasyon fonksiyonu, düşük bitli cihazlarda daha kararlı sonuçlar sağlamaktadır (Xuan Zhang ve arkadaşları, 2024).

Şekil 3.6, MobileNet-v2 mimarisindeki iki farklı blok yapısını açıklamaktadır: Adım boyutu = 1 blok ve adım boyutu = 2 blok. Bu bloklar, MobileNet-v2'nin verimli ve hafif bir model olmasını sağlayan ana yapı taşlarıdır. Özellikle Kanal Ayrılabilir Evrişim ve Noktasal Evrişim (1x1) evrişimler, standart evrişimlere kıyasla hesaplama maliyetini azaltmaktadır.

Adım boyutu = 1 blok, özellik haritasının uzamsal boyutunu korumaktadır. Bu blokta, ilk olarak 1×1 (genişletme) Noktasal Evrişim uygulanmakta ve ardından 3×3 Kanal Ayrılabilir Evrişim ile öznitelik çıkarımı gerçekleştirilmektedir. Son aşamada 1×1 (daraltma) Noktasal Evrişimi yardımıyla özellik kanalları orijinal boyutuna dönülmektedir. Aynı zamanda, girdi ile çıkış arasında eklenen atlama (skip) bağlantısı sayesinde artık blok yapısı oluşmaktadır.

Adım boyutu = 2 blok, özellik haritasının uzamsal boyutunu yarıya düşürmektedir. Bu blok, aynı aşamaları (genişletme, derinlikli evrişim, daraltma) izlemektedir; ancak 3×3 Kanal Ayrılabilir Evrişimde adım boyutu 2 olarak ayarlanmakta ve böylece uzamsal boyut yarıya inmektedir. Blok sonunda, yine 1×1 daraltma evrişimiyle kanal boyutu düşürülmekte fakat çoğu zaman adım boyutu = 2 bloklarda doğrudan atlama bağlantısı kısmen kullanılmamaktadır veya kullanılsa bile farklı biçimde uygulanmaktadır (Mark Sandler ve arkadaşları, 2018).



Şekil 3.6 MobileNet-v2 mimari yapısı

3.2.2.4. GoogleNet

GoogleNet, Google tarafından geliştirilen ve derin öğrenme tabanlı görüntü işleme görevlerinde kullanılan bir CNN mimarisidir. Bu model, hem hesaplama verimliliği hem de doğruluk oranları açısından oldukça başarılı performans göstermektedir. GoogleNet,

"Inception modülleri" adı verilen yenilikçi bir yapı sayesinde hem geniş hem de derin bir ağ oluştururken hesaplama yükünü minimumda tutmayı başarmaktadır.

GoogleNet, geleneksel CNN yapılarından farklı olarak, daha karmaşık ve çok boyutlu özellikleri aynı anda öğrenebilen Inception modülleri ile tasarlanmıştır. Bu modüller, 1x1 evrişimler kullanarak kanal sayısını azaltır ve böylece modelin daha az parametre içermesini sağlar. Bu modüller, farklı filtre boyutlarını bir arada kullanarak görüntü özelliklerini daha verimli bir şekilde çıkarmaktadır. Inception modülleri, farklı çekirdek boyutlarına sahip evrişim işlemlerini aynı anda gerçekleştirmekte ve bu işlemlerin sonuçlarını birleştirmektedir.

GoogleNet, 22 katmanlı olmasına rağmen yalnızca yaklaşık 5 milyon parametreye sahiptir. Bu durum, hesaplama verimliliğini önemli ölçüde artırmaktadır. Geleneksel modellerdeki tam bağlı katmanlar yerine, GoogleNet'in sonunda bir global ortalama havuzlama (*global average pooling*) katmanı bulunmaktadır. Bu yapı, parametre sayısını önemli ölçüde azaltmakta ve aşırı öğrenme (*overfitting*) riskini düşürmektedir. Global ortalama havuzlama, her bir özellik haritasının ortalamasını alarak sabit boyutlu bir vektör üretmekte ve bu vektör doğrudan sınıflandırma katmanına beslenmektedir. Bu yaklaşım, modelin daha genelleştirilebilir olmasını sağlamaktadır.

Inception modülleri, GoogleNet'in en önemli bileşenleridir. Bu modüller, 1x1, 3x3 ve 5x5 evrişim filtrelerini aynı anda kullanarak farklı ölçeklerdeki özellikleri çıkarmaktadır. Ayrıca, 3x3 maksimum havuzlama işlemi de modüle dahil edilerek yerel bilgi yoğunlaştırması sağlanmaktadır. 1x1 evrişimler, kanal sayısını azaltarak hesaplama maliyetini düşürmekte ve modelin daha verimli çalışmasına katkıda bulunmaktadır. Bu çoklu filtre boyutlarının birleştirilmesi, modelin farklı detay seviyelerindeki özellikleri aynı anda öğrenmesine olanak tanımaktadır (R Tamilarasi ve S Gopinathan, 2021).

GoogleNet'in bu mimarisi, özellikle geniş ölçekli görüntü veri setlerinde yüksek doğruluk oranları elde edilmesini mümkün kılmaktadır. Ayrıca, düşük parametre sayısı sayesinde modelin daha hızlı eğitilmesi ve daha az bellek kullanması sağlanmaktadır. Bu özellikler, GoogleNet'i özellikle gerçek zamanlı uygulamalar ve sınırlı kaynaklara sahip sistemler için ideal bir seçenek haline getirmektedir.

GoogleNet'in başarısı, sadece görüntü sınıflandırma görevleriyle sınırlı değildir. Bu mimari, nesne algılama, semantik segmentasyon ve diğer bilgisayarlı görü uygulamalarında da yaygın olarak kullanılmaktadır. Inception modüllerinin esnek yapısı,


farklı görevlere uyarlanabilir olmasını sağlamakta ve bu da GoogleNet'i derin öğrenme alanında önemli bir model haline getirmektedir.

Şekil 3.7, GoogleNet mimarisinin temel yapı taşlarından biri olan Inception modülünün detaylı bir şemasını sunmaktadır. Bu modül, derin öğrenme modellerinde özellik çıkarımını optimize etmek ve modelin hem hesaplama verimliliğini hem de tahmin gücünü artırmak amacıyla tasarlanmıştır. Inception modülü, giriş katmanını (*previous layer*) paralel olarak farklı boyutlarda işlemlerden geçirerek çoklu özellik çıkarımı yapmakta ve bu özellik haritalarını birleştirerek (*filter concatenation*) daha zengin bir özellik seti elde etmektedir.

Modülün tasarımında, farklı evrişim (*convolution*) ve havuzlama (*pooling*) işlemleri kullanılmaktadır. 1x1 evrişimler, kanal sayısını azaltarak hesaplama karmaşıklığını düşürmekte ve modelin daha verimli çalışmasını sağlarken 3x3 ve 5x5 evrişimler ise farklı ölçeklerdeki özellikleri öğrenmek için kullanılmaktadır. Bu durum, modelin hem küçük hem de büyük özellikleri yakalayabilmesini sağlamaktadır. 3x3 maksimum havuzlama işlemi ise yerel bilgi yoğunlaştırması yaparak, özellik haritalarının boyutunu küçültürken önemli bilgileri korumaktadır.

Inception modülünün bu paralel işlem yapısı, modelin hem derinliğini hem de genişliğini optimize etmektedir. Paralel yapılardan gelen bilgiler birleştirildiğinde model daha karmaşık ve çeşitli özellikleri öğrenebilmektedir.

Inception modülünün bu özellikleri, GoogleNet mimarisinin başarısının temelini oluşturmaktadır. Bu yapı, ImageNet gibi geniş ölçekli görüntü veri kümelerinde yüksek doğruluk oranları sağlamıştır. Inception modülünün esnek ve etkili tasarımı, diğer derin öğrenme modellerine de ilham vermiştir. Özellikle büyük veri setleriyle çalışırken, bu modül hem hesaplama kaynaklarının verimli kullanılmasını hem de yüksek performans elde edilmesini önemli ölçüde kolaylaştırmaktadır (Christian Szegedy ve arkadaşları, 2014).



Şekil 3.7 GoogleNet mimari yapısı

3.2.2.5. EfficientNet-b0

EfficientNet-b0, CNN mimarileri arasında verimlilik ve doğruluk açısından en başarılı modellerden biri sayılmaktadır. Google tarafından geliştirilmiştir. EfficientNet ailesinin bir üyesi olan bu model, doğruluk oranını artırırken aynı zamanda hesaplama maliyetini düşürmeyi hedeflemektedir.

EfficientNet-b0, derin öğrenme modellerinde kullanılan geleneksel yapıların ötesine geçerek "compound scaling" adı verilen optimize edilmiş bir ölçekleme yöntemiyle tasarlanmıştır (Sameh Abd El-Ghany ve arkadaşları, 2024). Bu yöntem; ağırlık genişliği, derinliği ve çözünürlüğünü dengeli bir şekilde artırarak hem doğruluğu hem de verimliliği arttırmaktadır.

EfficientNet-b0'nin temel yeniliği olan Compound Scaling (Bileşik Ölçekleme), model ölçekleme işlemini dengeli bir şekilde gerçekleştirme yaklaşımı sergilemektedir (M Tan ve Q Le, 2019). Bu yaklaşım; modelin genişliğini artırarak her katmandaki kanal sayısını, derinliğini artırarak katman sayısını ve çözünürlüğünü artırarak girdi görüntülerinin boyutlarını optimize bir şekilde genişletir. Böylece model hem daha karmaşık özellikleri öğrenebilmekte hem de girdi verilerindeki daha ince ayrıntıları işleyebilmektedir. Bu ölçekleme stratejisi, gereksiz parametre artışını önlerken tüm kaynakların verimli bir şekilde kullanılmasını sağlamak ve modelin doğruluk ile verimlilik arasında etkili bir

denge kurmasına olanak tanımaktadır (Madan Mohan Tito Ayyalasomayajula ve Sailaja Ayyalasomayajula, 2021).


EfficientNet-b0, MobileNetV2 mimarisinde kullanılan "inverted residual block" ve "depthwise separable convolution" gibi tekniklerden faydalanmaktadır (Atishek Kumar ve arkadaşları, 2022). Aktivasyon Fonksiyonu olarak Geleneksel ReLU yerine Swish aktivasyon fonksiyonu kullanılmaktadır.

Swish aktivasyon fonksiyonu, geleneksel ReLU'ya (*Rectified Linear Unit*) göre daha yumuşak bir aktivasyon fonksiyonudur ve bu özellik bazı durumlarda modelin doğruluğunu arttırmaktadır (JU Rahman ve arkadaşları, 2024). Swish'in doğruluğu artırma potansiyeli, özellikle daha karmaşık ve derin modellerde, öğrenme sırasında gradyanların akışını iyileştirmesi ve daha düzgün bir şekilde çalışabilmesinden kaynaklanmaktadır (Jamshaid Ul Rahman ve arkadaşları, 2024). Swish'in matematiksel formülü denklem 3.1'de sunulmuştur:

$$f(x) = x \cdot \text{sigmoid}(x) \quad (3.1)$$

Denklem 3.1' de yer alan formül, girdiyi bir sigmoid fonksiyonuyla çarpar ve bu da ReLU'ya göre daha az keskin bir geçiş sağlamaktadır. Bu formül, girdiyi bir sigmoid fonksiyonuyla çarpar ve bu da ReLU'ya göre daha az keskin bir geçiş sağlamaktadır. Ancak, Swish'in doğruluğu artırma etkisi, kullanılan veri seti ve model mimarisi gibi faktörlere bağlı olarak değişebilmektedir.

Şekil 3.8' de bulunan görsel, bir EfficientNet mimarisindeki temel katmanların düzenini göstermektedir. Giriş görüntüsü, ilk olarak standart bir 3x3 evrişimden geçirilmekte ve ardından çeşitli MBConv bloklarından (MobilenetV2'nin dar-geniş-dar yapılarını kullanan "Mobile Inverted Bottleneck Convolution" blokları) oluşan bir ardışık düzen izlemektedir (Abdulhalık Oğuz ve Ömer Faruk Ertuğrul, 2023). Bu bloklar, genellikle genişletme faktörü (örneğin, MBConv6 ile genişleme 6 katına çıkar) ve farklı filtre boyutları (3x3 veya 5x5) kullanılarak giriş verisindeki uzamsal ve kanal düzeyindeki özellikleri öğrenmektedir. Blokların tekrar sayıları (2x, 3x, vb.) modelin derinliğini kontrol etmekte ve bu tekrarlarla özellik çıkarım kapasitesi artırılmaktadır. EfficientNet'in bu tasarımı, hem hesaplama verimliliğini optimize ederken parametrik karmaşıklığı minimumda tutarak yüksek performanslı bir öğrenme sağlamaktadır.



Şekil 3.8 EfficientNet-b0 mimari yapısı

3.2.3. Transfer öğrenme

Transfer öğrenme (*transfer learning*), derin öğrenme modellerinde özellikle sınırlı veri setleriyle çalışırken yaygın olarak kullanılan bir tekniktir. Bu yöntem, geniş ve çeşitli veri kümeleri üzerinde eğitilmiş bir modelin sahip olduğu parametreleri ve temsilleri daha küçük ve özel bir veri setine uyarlanmasını sağlamaktadır. Transfer öğrenmesi, görüntü işleme, doğal dil işleme ve konuşma tanıma gibi alanlarda yaygın biçimde uygulanmakta olup, özellikle CNN bağlamında son derece başarılı sonuçlar üretmektedir (Yosinski ve arkadaşları, 2014).

Transfer öğrenmenin bir diğer avantajı, özellikle küçük veri kümelerinde aşırı öğrenmeyi önleme yeteneğidir. Büyük modeller, sınırlı veriyle eğitildiğinde eğitim verilerine aşırı uyum sağlama eğiliminde olmaktadır. Ancak, önceden eğitilmiş modellerin kullanılması modelin genelleme yeteneğini artırarak bu sorunu hafifletmektedir. Ayrıca, transfer öğrenme modelin daha hızlı yakınsamasını sağlamaktadır çünkü model zaten temel özellikleri öğrenmiş durumdadır ve yalnızca yeni göreve özgü özellikleri öğrenmesi gerekmektedir (A Hosna ve arkadaşları, 2022).

BÖLÜM 4. DENEYSEL SONUÇLAR

Tez çalışması kapsamında önerilen CNN tabanlı derin öğrenme modelleri, optimizasyon parametreleri ve eğitim parametreleri ile ette tüberküloz tespiti MATLAB R2022b platformunda gerçekleştirilmiştir. Gerçekleştirilen sınıflandırma tespitinde eğitim parametreleri sabit tutularak CNN'lerin ve optimizasyon parametrelerinin başarıları ölçülmüş olup bu ölçümlerin sonuçları paylaşılmıştır.

Modellerin eğitilmesi, eğitilen modellerin uygulamaları ve ölçümler sırasında Windows 10 işletim sistemi, Intel Core i7-12700H 2.70 GHz işlemci, Nvidia RTX 3070 grafik kartı ve 16GB RAM kullanılmıştır.

4.1. Model Parametreleri ve Değerlendirme Metrikleri

Modellerin etkin ve verimli bir şekilde eğitilebilmesi için model parametreleri optimize edilmiştir. 133 örnekten oluşan bir mini-batch boyutu ve 15' lik bir doğrulama sıklığı ile 3 epoch'luk bir eğitim süreci benimsenmiştir. SGD, Adam, RMSProp optimizasyon algoritmaları kullanılmıştır. Bu değerler, modellerin hızlı bir şekilde yakınsamasını sağlarken aynı zamanda aşırı uyumun önüne geçerek optimizasyonu sağlamıştır. Deneyler, tüm modeller için aynı ayarlar ve koşullar altında gerçekleştirilmiştir. Bu, farklı modellerin ve optimizasyon algoritmalarının performanslarının adil ve objektif bir şekilde karşılaştırılabilmesini sağlamaktadır. CNN kullanılarak tüberküloz teşhisi üzerine elde edilen deneysel sonuçların detaylı bu bölümde sunulmaktadır.

Bu çalışmada ResNet-50, DarkNet-53, GoogLeNet, MobileNetV2 ve EfficientNet-B0 gibi modern CNN mimarileri kullanılmıştır. Bu mimariler, derin ve karmaşık yapılarıyla, özellikle görsel veri üzerinde yüksek performans göstermektedir. Ancak, bu tür derin modellerin eğitimi sırasında parametre güncellemelerinin kararlılığı ve optimizasyon sürecinin etkinliği büyük önem taşımaktadır.

5 farklı derin öğrenme modeli ve her biri için SGDM, Adam, RMSProp optimizasyon algoritmaları seçilerek karmaşıklık matrisi verileri elde edilmiştir.

SGDM'nin momentum mekanizması, bu modellerde parametre güncellemelerinin daha tutarlı ve istikrarlı olmasını sağlayarak, genelleme yeteneğini güçlendirmektedir (Zhiwei Lin ve arkadaşları, 2023). Ayrıca, momentum özellikle derin modellerde gradyanların daha hızlı ve etkin bir şekilde güncellenmesine olanak tanıyarak, eğitim sürecinin daha verimli ve hızlı bir şekilde tamamlanmasını sağlamaktadır (Igor Gitman ve arkadaşları, 2019).

SGDM'nin bu çalışmada tercih edilmesinin diğer bir nedeni, momentum mekanizmasının dengeli veri kümelerinde gradyanların daha tutarlı bir şekilde güncellenmesini sağlamasıdır (Zhao Chen ve arkadaşları, 2018). Dengeli veri kümelerinde her sınıfın eşit sayıda örneğe sahip olması, gradyanların her sınıf için benzer büyüklükte ve yönde olmasını sağlamaktadır.

SGDM, aşırı uyum riskini azaltmada oldukça etkilidir (Khairul Khaizi ve arkadaşları, 2022). Dengeli veri kümelerinde, tüm sınıflardan eşit şekilde öğrenme sağlanacağı için SGDM'nin sabit yapısı, genelleme performansını artırmaktadır.

Adam, klasik SGD'yi geliştiren bir diğer popüler optimizasyon yöntemidir. Bu yöntem, klasik SGD iyileştirmeye odaklanarak her bir parametre için hem birinci (ortalama gradyan) hem de ikinci momenti (ortalama gradyanın karesi) uyarlamalı biçimde izlemektedir (Xingyu Xie ve arkadaşları, 2024).

Adam, her bir parametre için ayrı bir öğrenme oranı hesabı yapmaktadır. Böylece, sık veya seyrek güncellenmesi gereken parametreler arasındaki öğrenme oranı dengesini kurarak eğitimin daha istikrarlı ilerlemesini desteklemektedir (Liyuan Liu ve arkadaşları, 2019). Özellikle bu çalışmada kullanılan derin ve karmaşık mimarilerde (ResNet-50, DarkNet-53, GoogLeNet, MobileNetV2, EfficientNet-B0) farklı katmanlardaki parametrelerin öğrenme ihtiyaçları da farklılık gösterebildiğinden, Adam'ın adaptif yapısı bu tür durumlarda avantaj sağlamaktadır.

RMSProp, SGD'yi geliştiren ve özellikle değişken veya gürültülü gradyan davranışlarına uyum sağlayan bir optimizasyon yöntemidir.

RMSProp optimizasyon algoritması, her bir parametrenin gradyanlarının karesine ait üstel hareketli ortalamaları (EMA) takip ederek, ağırlık farklı katmanlarında ve değişen veri koşullarında uyarlanabilir bir öğrenme oranı sunmaktadır.

Büyük veri kümelerinin işlendiği derin öğrenme uygulamalarında, bellek maliyeti ve hesaplama süresi kritik öneme sahiptir. RMSProp, yalnızca gradyanların karesinin üstel

hareketli ortalamasını saklayarak ek bellek kullanımını minimal düzeyde tutmaktadır. Bu durum, sığır eti görüntülerinde bTB tespiti gibi kapsamlı veri işlemlerini daha verimli bir şekilde yapabilme olanağı sunmaktadır. Özellikle yüksek çözünürlüklü görüntülerde ya da daha büyük batch boyutlarıyla çalışılırken bellek kullanımında sağladığı avantaj sayesinde, eğitim süreci daha yüksek stabilite ile yürütülmektedir (Swaleha Zubair, 2023).

Bu çalışmada, farklı derin öğrenme yaklaşımlarının etkinliğini ve başarımını değerlendirmek amacıyla çeşitli metrikler kullanılmıştır. Değerlendirme metrikleri, modelin hem sınıflandırma doğruluğunu hem de genelleme kapasitesini ölçmek için kritik öneme sahiptir (Chiyuan Zhang ve arkadaşları, 2021). Kullanılan metrikler arasında kesinlik (*Precision*), duyarlılık (*Recall*), F1 skoru (*F1 score*) ve doğruluk (*Accuracy*) bulunmaktadır. Karmaşıklık matrisi ile Yanlış negatif, pozitif, yanlış pozitif, doğru negatif ve doğru pozitif değerleri üzerinden hesaplamalar yapılmaktadır.

Doğru pozitif, gerçekten tüberküloz ile enfekte olmuş hayvansal ürünlerin doğru bir şekilde tüberküloz olarak sınıflandırıldığı durumların sayısını ifade etmektedir. Bu durum modelin enfekte ürünleri tespit etme başarısını gösterir.

Yanlış pozitif, Sağlıklı olan hayvansal ürünlerin yanlış bir şekilde tüberküloz olarak sınıflandırıldığı durumları ifade eder. Yanlış pozitif durumlar, modelin sağlıklı ürünlere gereksiz yere tüberküloz teşhisi koyması anlamına gelir.

Yanlış negatif, Gerçekten tüberküloz ile enfekte olan hayvansal ürünlerin yanlış bir şekilde sağlıklı olarak sınıflandırıldığı durumların sayısını ifade eder.

Doğru negatif, Sağlıklı hayvansal ürünlerin doğru bir şekilde sağlıklı olarak sınıflandırıldığı durumları ifade eder. Bu durum, modelin sağlıklı ürünleri yanlış bir şekilde enfekte olarak sınıflandırmaktan kaçınma başarısını gösterir. Şekil 4.1’de karmaşıklık matrisi verilmiştir. Verisetinde 1400 adet eğitim ve 600 adet test verisi bulunmaktadır.

	bTB Enfekte (0)	Sağlıklı(1)
bTB Enfekte (0)	TP	FP
Sağlıklı(1)	FN	TN

Şekil 4.1 Karmaşıklık Matrisi

Precision metriği, modelin tüberküloz olduğunu belirttiği hayvansal ürünlerin ne kadarının gerçekten enfekte olduğunu ölçer. Bu metrik, yanlış pozitif durumların etkisini minimize etmek için kullanılır. Doğru pozitif (TP) değerinin, doğru pozitif (TP) ve yanlış pozitif (FP) toplamına oranı ile hesaplanır ve denklem 4.1’ deki gibi formülize edilmektedir:

$$Kesinlik = \frac{TP}{TP + FP} \quad (4. 1)$$

Doğruluk değeri yüksek bir model yanlış pozitif sınıflandırmaların sayısını düşük tutarak güvenilir teşhisler sunar. Bu durum özellikle enfekte olmayan ürünlere yönelik yanlış alarmların azaltılmasında önemlidir. Duyarlılık metriği, modelin gerçekten enfekte olan hayvansal ürünleri doğru bir şekilde tespit edebilme yeteneğini ölçer. Doğru pozitif (TP) değerinin, doğru pozitif (TP) ve yanlış negatif (FN) toplamına oranı ile hesaplanır ve denklem 4.2’ deki gibi formülize edilmektedir:

$$Duyarlılık = \frac{TP}{TP + FN} \quad (4. 2)$$

F1 skoru, precision ve recall metriklerinin harmonik ortalamasıdır ve her iki metrik arasında bir denge sağlar. Hem yanlış pozitifleri hem de yanlış negatifleri dikkate alarak modelin genel başarımını yansıtır. Formülü denklem 4.3’ te verilmiştir.

$$F1 \text{ Skoru} = 2 \times \frac{\text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (4.3)$$

F1 skoru, Precision ve Recall değerleri arasında bir denge sağlaması nedeniyle özellikle sınıflar arasında dengesizlik olduğu durumlarda önemlidir. Bu çalışmada F1 skoru, modelin enfekte ürünleri doğru bir şekilde sınıflandırma yeteneğini kapsamlı bir şekilde değerlendirmek için kullanılmıştır (David J. Hand ve arkadaşları, 2021).

Doğruluk metriği, modelin genel doğruluğunu ifade eder ve hem doğru pozitif hem de doğru negatif sınıflandırmaların oranını ölçer. Toplam doğru sınıflandırmaların (TP ve TN), toplam sınıflandırma sayısına (TP + TN + FP + FN) oranı ile hesaplanır. Doğruluk Denklem 4.4 ile formülize edilmektedir:

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \quad (4.4)$$

Tablo 4.1 Evrişimli sinir ağı model parametreleri

Evrişimsel Sinir Ağı Modelleri	Girdi Boyutu	Derinlik
ResNet-50	224x224	50
DarkNet-53	224x224	53
MobileNet-v2	224x224	51
GoogleNet	224x224	22
EfficientNet-b0	224x224	82

Tablo 4.1’de evrişimli sinir ağı modellerinin model parametreleri verilmiştir.

Tablo 4.2 Önerilen ResNet-50 mimarisinin detayları

Katman Tipi	Katman Detayları	Çıktı Boyutu	Parametreler
Giriş	-	224x224x3	-
Evrişimsel (Evr1)	64 filtre, 7x7 çekirdek, adım=2, doldurma=aynı	112x112x64	9,472
Maksimumu Havuzlama (Havuz1)	3x3 havuzlama, adım=2	56x56x64	0
Evrişimsel Blok	3x [64 filtre, 1x1, 3x3, 1x1]	56x56x256	75,008
Evrişimsel Blok	4x [128 filtre, 1x1, 3x3, 1x1]	28x28x512	378,880
Evrişimsel Blok	6x [256 filtre, 1x1, 3x3, 1x1]	14x14x1024	1,512,448
Evrişimsel Blok	3x [512 filtre, 1x1, 3x3, 1x1]	7x7x2048	3,024,896
Ortalama Havuzlama	7x7 havuz boyutu, adım=1	1x1x2048	0
Tam Bağlantılı (TB)	1000 nöron, Softmax aktivasyonu	1000	2,049,000

Tablo 4.2’de önerilen ResNet-50 mimarisinin detayları sunulmuştur.

Tablo 4.3 Önerilen DarkNet-53 mimarisinin detayları

Katman Tipi	Katman Detayları	Çıktı Boyutu	Parametreler
Giriş	-	256x256x3	-
Evrişimsel	32 filtre, 3x3 çekirdek, adım=1	256x256x32	896
Evrişimsel	64 filtre, 3x3 çekirdek, adım=2	128x128x64	18,496
Evrişimsel Blok	1x [32, 3x3]	128x128x64	36,864
Evrişimsel	128 filtre, 3x3 çekirdek, adım=2	64x64x128	73,728
Evrişimsel Blok	2x [64, 3x3]	64x64x128	147,456
Evrişimsel	256 filtre, 3x3 çekirdek, adım=2	32x32x256	295,424
Evrişimsel Blok	8x [128, 3x3]	32x32x256	2,359,296
Evrişimsel	512 filtre, 3x3 çekirdek, adım=2	16x16x512	1,180,160
Evrişimsel Blok	8x [256, 3x3]	16x16x512	9,437,184
Evrişimsel	1024 filtre, 3x3 çekirdek, adım=2	8x8x1024	4,720,896
Evrişimsel Blok	4x [512, 3x3]	8x8x1024	18,874,368
Ortalama Havuzlama	8x8 havuz boyutu, adım=1	1x1x1024	0
Tam Bağlantılı (TB)	1000 nöron, Softmax aktivasyonu	1000	1,025,000

Tablo 4.3’te önerilen DarkNet-53 mimarisinin detayları sunulmuştur.

Tablo 4.4 Önerilen MobileNet-v2 mimarisinin detayları

Katman Tipi	Katman Detayları	Çıktı Boyutu	Parametreler
Giriş	-	224x224x3	-
Evrişimsel	32 filtre, 3x3 çekirdek, adım=2	112x112x32	864
Derinlik Ayrımlı	1x [32 filtre, 3x3, adım=1]	112x112x32	1,152
Evrişimsel	16 filtre, 1x1 çekirdek, adım=1	112x112x16	512
Derinlik Ayrımlı	1x [96 filtre, 3x3, adım=2]	56x56x96	8,064
Evrişimsel Blok	5x [24, 1x1, 3x3, 1x1]	28x28x24	18,432
Evrişimsel Blok	8x [32, 1x1, 3x3, 1x1]	14x14x32	23,040
Evrişimsel Blok	8x [64, 1x1, 3x3, 1x1]	7x7x64	34,560
Evrişimsel Blok	1x [128, 1x1, 3x3, 1x1]	7x7x128	67,584
Ortalama Havuzlama	7x7 havuz boyutu, adım=1	1x1x1280	0
Tam Bağlantılı (TB)	1000 nöron, Softmax aktivasyonu	1000	1,281,000

Tablo 4.4’te önerilen MobileNet-v2 mimarisinin detayları sunulmuştur.

Tablo 4.5 Önerilen GoogleNet mimarisinin detayları

Katman Tipi	Katman Detayları	Çıktı Boyutu	Parametreler
Giriş	-	224x224x3	-
Evrişimsel	64 filtre, 7x7 çekirdek, adım=2	112x112x64	9,472
Maksimumu Havuzlama	3x3 havuz boyutu, adım=2	56x56x64	0
Evrişimsel	192 filtre, 3x3 çekirdek, adım=1	56x56x192	110,784

Tablo 4.5. (Devamı) Önerilen GoogleNet mimarisinin detayları

Maksimumu Havuzlama	3x3 pool size, adım=2	28x28x192	0
Başlangıç Modülü	3x [256 filtre, çoklu çekirdek]	28x28x256	330,240
Başlangıç Modülü	3x [480 filtre, çoklu çekirdek]	14x14x480	1,144,160
Maksimumu Havuzlama	3x3 havuz boyutu, adım=2	14x14x480	0
Başlangıç Modülü	5x [832 filtre, çoklu çekirdek]	7x7x832	3,138,816
Başlangıç Modülü	2x [1024 filtre, çoklu çekirdek]	7x7x1024	6,999,552
Ortalama Havuzlama	7x7 havuz boyutu, adım=1	1x1x1024	0
Tam Bağlantılı (TB)	1000 nöron, Softmax aktivasyonu	1000	1,025,000

Tablo 4.5'te önerilen GoogleNet mimarisinin detayları sunulmuştur.

Tablo 4.6 Önerilen EfficientNet-b0 mimarisinin detayları

Katman Tipi	Katman Detayları	Çıktı Boyutu	Parametreler
Giriş	-	224x224x3	-
Evrişimsel	32 filtre, 3x3 çekirdek, adım=2	112x112x32	864
Ters Şişirme Evrişim Blok	1x [16, 3x3, adım =1]	112x112x16	1,424
Ters Şişirme Evrişim Blok	2x [24, 3x3, adım =2]	56x56x24	7,744
Ters Şişirme Evrişim Blok	2x [40, 3x3, adım =2]	28x28x40	31,744
Ters Şişirme Evrişim Blok	3x [80, 3x3, adım =2]	14x14x80	82,080
Ters Şişirme Evrişim Blok	3x [112, 3x3, adım =1]	14x14x112	146,048
Ters Şişirme Evrişim Blok	4x [192, 3x3, adım =2]	7x7x192	514,480
Ters Şişirme Evrişim Blok	1x [320, 3x3, adım =1]	7x7x320	304,640
Evrişimsel	1280 filtre, 1x1 çekirdek, adım=1	7x7x1280	410,880
Ortalama Havuzlama	7x7 havuz boyutu, adım =1	1x1x1280	0
Tam Bağlantılı (TB)	1000 nöron, Softmax aktivasyonu	1000	1,281,000

Tablo 4.6'da önerilen EfficientNet-b0 mimarisinin detayları sunulmuştur.

4.2. Model Eğitim Süreçleri

Bu bölümde, çalışmada kullanılan modelin eğitim ve test süreçleri ele alınmaktadır. Eğitim ve test veri ayrımı bir derin öğrenme modelinin doğruluğunu ve genelleme kapasitesini etkileyen kritik bir adımdır. Modelin eğitimi için kullanılmış olan veri kümesi, test ve eğitim aşamalarına yönelik olarak belirli bir oranla ayrılmıştır. Bu çalışmada veri kümesindeki görüntüler %70 eğitime ayrılan veri ve %30 teste ayrılan veri olacak şekilde bölünmüştür. Bu oran makine öğrenimi ve derin öğrenme literatüründe yaygın olarak kullanılan ve genelleme performansını optimize eden bir yaklaşımdır (Kamila Pawluszek-Filipiak ve Andrzej Borkowski, 2020).

4.3. Deneysel Sonuçlar

Bu bölümde, önerilen derin öğrenme modellerinin performansını değerlendirmek amacıyla gerçekleştirilen deneylerin sonuçları detaylı bir şekilde sunulmaktadır. Deneyler için tüberküloz ile enfekte olmuş ve sağlıklı sığır eti örneklerinden oluşan kapsamlı bir veri seti toplanmış ve işlenmiştir. Optimizasyon sürecinde Adam, RMSProp ve SGDM olmak üzere literatürde yaygın olarak kullanılmış olan üç farklı optimizasyon algoritması ile çalışılmıştır. Modellerin etkin ve verimli bir şekilde eğitilebilmesi çalışmada 5'lik bir doğrulama sıklığı ile 3 epoch'luk bir eğitim süreci benimsenmiştir. Bu ayarlar, modellerin hızlı bir şekilde yakınsamasını ve aşırı uyumdan kaçınmasını sağlamak için optimize edilmiştir. Geleneksel veri artırma teknikleriyle, GAN ile veri artırma teknikleriyle ve veri artırma işlemleri uygulanmadan yapılan deney sonuçları aşağıdaki tablolarda verilmiştir.

Tablo 4.7 Veri artırma uygulanmadan yapılan deneysel sonuçlar

Model	Optimizasyon Algoritması	Doğruluk (%)	F1-Skoru (%)
ResNet-50	RmsProp	97.84	97.84
	Adam	100.00	100.0
	Sgdm	100.0	100.0
DarkNet-53	RmsProp	98.56	98.43
	Adam	99.28	99.08
	Sgdm	97.84	97.67
MobileNet-v2	RmsProp	100.0	100.0
	Adam	98.56	100.0
	Sgdm	99.83	99.83
GoogleNet	RmsProp	98.56	98.56
	Adam	100.0	100.0
	Sgdm	100.0	100.0
EfficientNet-b0	RmsProp	100.0	100.0
	Adam	100.0	100.0
	Sgdm	100.0	100.0

Tablo 4.7' de veri artırmadan yapılan deney sonuçları sunulmaktadır.

Tablo 4.8 Geleneksel Veri Artırma ile Deneysel sonuçlar

Model	Optimizasyon Algoritması	Doğruluk (%)	F1-Skoru (%)
ResNet-50	RmsProp	97.0	96.99
	Adam	97.17	97.1
	Sgdm	100.0	100.0
DarkNet-53	RmsProp	75.33	79.84
	Adam	96.0	95.83
	Sgdm	99.67	99.67
MobileNet-v2	RmsProp	98.0	98.04
	Adam	100.0	100.0
	Sgdm	99.83	99.83
GoogleNet	RmsProp	95.0	94.74
	Adam	97.67	97.71
	Sgdm	98.0	98.04
EfficientNet-b0	RmsProp	100.0	100.0
	Adam	99.5	99.5
	Sgdm	100.0	100.0

Tablo 4.8’de Geleneksel veri artırma yapılarak oluşturulan veri kümesinin deney sonuçları paylaşılmıştır.

Tablo 4.9 GAN ile Artırılmış Verilerin Deneysel sonuçları

Model	Optimizasyon Algoritması	Doğruluk (%)	F1-Skoru (%)
ResNet-50	RmsProp	81.06	74.26
	Adam	81.06	74.26
	Sgdm	81.33	74.73
DarkNet-53	RmsProp	81.06	74.26
	Adam	81.19	74.50
	Sgdm	81.06	74.26
MobileNet-v2	RmsProp	81.06	74.26
	Adam	81.06	74.26
	Sgdm	85.39	81.25
GoogleNet	RmsProp	81.87	75.64
	Adam	84.17	79.37
	Sgdm	81.46	74.95
EfficientNet-b0	RmsProp	81.06	74.26
	Adam	81.06	74.26
	Sgdm	86.47	82.88

4.3.1. ResNet-50 ve optimizasyon algoritmaları performans değerlendirmesi

a) Geleneksel veri artırma tekniği uygulanarak yapılmış deneylerde performans

SGDM’nin optimizasyon algoritması olarak kullanıldığı senaryoda, ResNet-50 modeli kusursuz bir sınıflandırma doğruluğuna ulaşmıştır. Tüm 300 tüberküloz örneğini ve tüm

300 sağlıklı örneği doğru bir şekilde tanımlamıştır. Bu durumda, Şekil 4.2’ de gösterilmiş olduğu gibi, hiçbir yanlış negatif (FN: sağlıklı örneklerin tüberküloz enfekte olarak yanlış tanımlanması) veya yanlış pozitif (FP: tüberküloz enfekte örneklerin sağlıklı olarak yanlış tanımlanması) gözlenmemiştir. Bu sonuç, ResNet-50 modelinin SGDM ile etkili bir şekilde eğitildiğini ve yüksek bir genelleme yeteneğine sahip olduğu açıkça görülmektedir. Buna karşın RMSProp ve Adam optimizasyon algoritmaları kullanıldığında yanlış negatif sayısının daha yüksek olduğu ve modelin performansının düştüğü gözlemlenmiştir.



Şekil 4.2 ResNet-50 için karmaşıklık matrisi (a) RMSProp, (b) Adam (c) SGDM

ResNet-50 mimarisi, çok katmanlı yapısı ve residual blokları sayesinde derin özellik temsilini başarıyla gerçekleştirebilen bir ağıdır. Bu derinlik, eğitimin istikrar kazanmasında kritik bir rol oynayan optimizasyon algoritmalarını daha da önemli hale getirmektedir (Xin-Wei Wang ve arkadaşları, 2023). SGDM, güncel gradyan dalgalanmalarını yumuşatan momentum terimiyle, çok katmanlı ağların parametre güncellemelerinde daha pürüzsüz bir yaklaşım sunmaktadır. Böylece model, özellikle tüberküloz gibi belirli yapısal farklılıklara sahip veri setlerinde, doğru özellikleri vurgulayarak daha başarılı şekilde sınıflandırmaya olanak tanımaktadır. Nitekim ResNet-50’nin SGDM ile tüm örnekleri hatasız sınıflandırması, momentum tabanlı bu algoritmanın derin katmanlarda kararlı bir iyileşme sürecini mümkün kıldığını göstermektedir (Ruslan Abdulkadirov ve arkadaşları, 2023).

RMSProp ise, her bir parametreye göre uyarlanmış öğrenme oranı belirleyerek belirli senaryolarda etkili olabilse de, ResNet-50 gibi geniş ve derin bir mimaride zaman zaman yeterince kararlı bir yakınsama gerçekleştiremez (Mainak Mitra ve Soumit Roy, 2023). Özellikle çok katmanlı bir ağın yüksek boyutlu parametre uzayında, RMSProp’un adaptif güncellemeleri bazen keskin dalgalanmalara veya lokal minimumlarda sıkışmaya yol açabilmektedir. Bu durum, sınıflandırma esnasında hata oranını artırarak tüberküloz

enfekte ve sağlıklı örnekleri birbirinden ayırmada SGDM kadar istikrarlı bir performans sunamamasına neden olabilmektedir. Bu yüzden RMSProp, ResNet-50 mimarisinde en düşük doğruluk oranını getiren optimizasyon yöntemi olarak öne çıkmıştır.

Adam, adaptif moment tahmini mekanizması sayesinde derin modellerde hızlı olduğu kadar verimi yüksek bir öğrenme süreci sağlayan popüler bir algoritmadır. ResNet-50 üzerinde RMSProp'a kıyas edildiğinde daha yüksek bir doğruluk değeri (%97.17) ve F1-Skoru (%97.1) elde etmesi, Adam'ın öğrenme oranlarını gradyanların büyüklüğüne göre uyarlamada genellikle başarılı olduğunun bir göstergesidir. Ancak Adam'ın esnek güncelleme yapısı her ne kadar hızlı yakınsamayı kolaylaştırırsa da, SGDM'nin sunduğu kadar güçlü bir genelleme ve kararlılık elde etmekte her zaman aynı başarıyı sağlayamayabilmektedir (Xingyu Xie ve arkadaşları, 2024). Bu nedenle ResNet-50 gibi derin ve residual bağlantılı bir ağda, Adam'ın performansı RMSProp'ı geride bırakmasına rağmen momentum mekanizmasıyla desteklenmiş SGDM'nin gerisinde kalmıştır.

b) Veri Artırma Uygulanmadan Yapılan Deneyler

Veri artırma tekniklerinin hiç kullanılmadığı senaryoda, ResNet-50 modelinde optimizasyon algoritmalarının performansında belirgin farklılıklar gözlemlenmiştir. Adam ve SGDM kullanıldığında %100 doğruluk ve %100 F1-skoru elde edilirken, RMSProp ile elde edilen sonuçlarda %97.84 doğruluk ve %97.84 F1-skoru kaydedilmiştir. Bu durum, modelin orijinal veriler üzerinde oldukça başarılı bir şekilde eğitilebildiğini ancak RMSProp'un bazı durumlarda optimizasyon sürecinde hafif geride kaldığını ortaya koymaktadır.

c) GAN ile Veri Artırma Uygulanarak Yapılmış Deneylerde Performans

GAN tarafından oluşturulan verilerle yapılan deneylerde ise ResNet-50 modelinin performansında gözle görülür bir düşüş yaşanmıştır. RMSProp, Adam ve SGDM optimizasyon algoritmalarının kullanıldığı senaryolarda sırasıyla yaklaşık %81 doğruluk ve %74-75 F1-skoru elde edilmiştir. Bu sonuçlar, GAN temelli veri artırmanın orijinal veri dağılımıyla birebir örtüşmeyen özellikler içerebildiğini ve dolayısıyla modelin genelleme yeteneğinde olumsuz bir etki yarattığını göstermektedir. Özellikle tüberküloz gibi hassas sınıflandırma gerektiren durumlarda, GAN ile üretilen veriler modelin ayırt edici özellikleri yeterince net öğrenememesine yol açabilmektedir.

4.3.2. Darknet-53 ve optimizasyon algoritmaları performans değerlendirme

a) Geleneksel veri artırma tekniği uygulanarak yapılmış deneylerde performans

DarkNet-53 modeli, RMSProp optimizasyon algoritması ile birlikte kullanıldığında 141 doğru negatif (TN) ile birlikte, 7 sağlıklı görüntüyü tüberküloz olarak yanlış sınıflandırmış ve bu da 7 yanlış negatif ile sonuçlanmıştır. Adam optimizasyon algoritması kullanıldığında yanlış negatif örnek sayısı daha da artmıştır. SGDM optimizasyon algoritması ise oldukça başarılı sonuç vermiştir. Şekil 4.3’ te farklı optimizasyon algoritmaları ile modelin performansı detaylı bir şekilde sunulmuştur.

Output Class		Target Class	
		H	TI
H	293	141	
TI	7	159	

Output Class		Target Class	
		H	TI
H	276	0	
TI	24	300	

Output Class		Target Class	
		H	TI
H	299	1	
TI	1	299	

Şekil 4.3 DarkNet-53 için karmaşıklık matrisi (a) RMSProp, (b) Adam (c) SGDM

DarkNet-53, ağırlıklı olarak nesne algılama ve nesneleri sınıflandırma gibi görevlerde yaygın biçimde kullanılan, derin katman yapısını özenli bir biçimde yapılandırmış CNN mimarilerindendir. Bu mimari, konvolüsyon katmanları ve yoğun bağlantıları sayesinde veri içerisindeki karmaşık desenleri yakalamakta oldukça başarılı olsa da elde edilmiş olan performans seçilen optimizasyon algoritması ile büyük ölçüde etkilenebilmektedir (Shuang Cong & Yang Zhou, 2023).

RMSProp kullanıldığında model, doğruluk oranında belirgin biçimde düşük bir seviyede kalmış (%75.33) ve hata oranı özellikle tüberküloz sınıflandırmasında modelin genelleme yeteneğini kısıtlamıştır. Adaptif öğrenme oranı mekanizmasına sahip olmasına rağmen RMSProp, DarkNet-53’ün katman sayısı ve parametre yoğunluğu nedeniyle modelin parametre uzayında tutarlı bir iyileşme sağlayamadığından, bazı kritik özellikleri öğrenmekte yetersiz kalmış görünmektedir. Bu durum, RMSProp’un her bir parametreye farklı bir öğrenme oranı atayan güncelleme yaklaşımının, DarkNet-53 gibi katmanlar arası etkileşimin yoğun olduğu mimarilerde beklenen düzeyde stabilizasyon sunmamasıyla ilişkilendirilebilmektedir.

Adam, aynı şekilde adaptif öğrenme oranları kullansa da ek olarak moment terimi (yani birinci ve ikinci dereceden momentlerin tahmin edilmesi) sayesinde derin yapılarda daha hızlı ve verimli bir yakınsama elde edebilmektedir (Fangyu Zou ve arkadaşları, 2019). DarkNet-53 üzerinde RMSProp'a kıyasla çok daha yüksek bir doğruluk oranı (%96.0) yakalayan Adam, tüberküloz enfekte örneklerin ayırt edici özelliklerini tanımada belirgin bir gelişim sağlamış ve yanlış negatiflerin azalmasına katkıda bulunmuştur. Ancak adaptif öğrenme yaklaşımı, hiperparametre ayarlarına karşı oldukça hassas olduğundan, bazı durumlarda aşırı uyum veya lokal minimumlarda takılma risklerini beraberinde getirebilmektedir (Bernd Bischl ve arkadaşları, 2023). Nitekim DarkNet-53 gibi katman sayısının yüksek olduğu yapılarda, Adam her ne kadar verimli bir çözüm bulma eğiliminde olsa da modelin tüm parametre uzayını kapsayan bir stabil yakınsama elde etmesi, momentumlu yaklaşımlara göre daha tutarsız kalabilmektedir.

SGDM ise DarkNet-53 üzerinde son derece başarılı bir sonuç ortaya koymuş ve %99.67 doğruluk oranıyla neredeyse kusursuza yakın bir performans sergilemiştir. Buradaki kilit unsur, momentum teriminin eğitimin ilerleyen aşamalarında gradyan dalgalanmalarını yumuşatarak daha kararlı bir güncelleme süreci sağlamasıdır (Byeongho Heo ve arkadaşları, 2020). DarkNet-53 mimarisinin katman yapısı, özellik çıkarma kabiliyeti ve yüksek parametre sayısı, nitelikli bir öğrenme sürecine ihtiyaç duyar. Momentum, güncel gradyan bilgilendirmesini geçmiş güncellemelerle harmanlayarak parametrelerin daha sağlıklı bölgelere doğru yönelmesine katkı sağlamaktadır. Böylece DarkNet-53 tüberküloz örneklerindeki kendine özgü doku özelliklerini tutarlı şekilde öğrenebilmekte ve bu yüksek genelleme yeteneği, doğruluk ve F1-skordaki artışla kendini göstermektedir.

b) Veri Artırma Uygulanmadan Yapılan Deneyler

Orijinal veri seti kullanıldığında tüm optimizasyon algoritmaları oldukça yüksek performans göstermiştir. Bu senaryoda Adam, en yüksek başarıyı sergilemiş, ancak farklar görece küçük olmuştur. Veri setinin doğal dağılımı korunmuş olduğundan, optimizasyon sürecinde herhangi bir fazladan gürültü veya sapma meydana gelmemiştir. Bu durum, her üç algoritmanın da orijinal veride etkili bir şekilde çalışabildiğini, ancak adaptif mekanizması sayesinde adamın biraz daha öne çıktığını göstermektedir.

c) GAN ile Veri Artırma Uygulanarak Yapılmış Deneylerde Performans

GAN ile artırılmış verilerde DarkNet-53'ün tüm optimizasyon algoritmalarında benzer şekilde görece düşük performans göstermesinin temelinde, GAN'ların orijinal veri setinin karmaşık yapısal ve dokusal özelliklerini tam olarak yansıtamaması yatmaktadır. SGDM, momentum terimi sayesinde genellikle gradyan dalgalanmalarını yumuşatarak daha stabil bir yakınsama sağlar; ancak GAN ile oluşturulan verilerde, orijinal dağılımdan sapmaların getirdiği belirsizlik, momentumun sağladığı bu dengeleyici etkiyi tam anlamıyla ortaya koymasını engellemiştir. Adam, adaptif öğrenme oranları ve moment tahminlerini kullanarak hızlı ve etkili bir yakınsama sağlamaya çalışmaktadır; fakat GAN verilerinde bulunan yapaylık ve gürültü, adaptif mekanizmasının fazla esnek davranmasına ve öğrenme sürecinde istenmeyen sapmalar oluşmasına neden olmaktadır. RMSProp ise her parametre için uyarlanmış öğrenme oranları kullanarak belirli durumlarda üstün sonuçlar verebilse de, GAN verilerinde yer alan dağılım bozuklukları, parametre güncellemelerinde tutarsızlığa yol açarak modelin genel başarısını düşürmektedir. Bu nedenlerle, GAN ile artırılmış veriler kullanıldığında, her üç optimizasyon algoritması da kendi avantajlarını tam olarak kullanamamakta ve sonuç olarak DarkNet-53 için benzer, görece düşük performans değerleri ortaya çıkmaktadır.

4.3.3. MobileNet-v2 ve optimizasyon algoritmaları performans değerlendirmesi

a) Geleneksel veri artırma tekniği uygulanarak yapılmış deneylerde performans

MobileNet-v2 modeli, Adam optimizasyon algoritması ile kusursuz bir sınıflandırma doğruluğuna ulaşmıştır. Şekil 4.4' te gösterilmiş olduğu gibi tüm 300 tüberküloz örneğini ve tüm 300 sağlıklı örneği doğru bir şekilde tanımlamıştır; bu durumda hiçbir yanlış negatif veya yanlış pozitif bulunmamaktadır. Ancak, RMSProp ve SGDM optimizasyon algoritmaları kullanıldığında da model yüksek bir doğruluk elde etmiş ve yanlış negatif örnek sayıları 0 olarak hesaplanmıştır. Bu sonuçlar, MobileNet-v2 modelinin farklı optimizasyon algoritmaları ile genel olarak başarılı olacak şekilde performans sergilediğini göstermektedir.

Output Class	H	300	12
	TI	0	288
		H	TI
		Target Class	

Output Class	H	300	0
	TI	0	300
		H	TI
		Target Class	

Output Class	H	300	1
	TI	0	299
		H	TI
		Target Class	

Şekil 4.4 MobileNet-v2 için karmaşıklık matrisi (a) RMSProp, (b) Adam (c) SGDM

MobileNet-v2'nin katmanları, öz nitelikleri itibarıyla diğer derin CNN modellerine kıyasla daha sınırlı sayıda parametre içerdiğinden ve veri akışını verimli biçimde düzenlediğinden, optimizasyon algoritmalarının hızla yakınsamaya ulaşma potansiyelini artırmaktadır (Aurelia Michele ve arkadaşları, 2019). Modelin sahip olduğu bu hafif yapı, öğrenme sürecinin üç farklı optimizasyon yaklaşımıyla da genel olarak başarılı sonuçlar vermesini sağlamıştır. Ancak elde edilen sonuçlar, optimizasyon algoritmalarının kendi dinamikleriyle modelin parametre dağılımı arasındaki etkileşimin farklı sonuçlara yol açtığını göstermektedir.

Adam, parametre güncellemelerinde birinci ve ikinci dereceden momentleri adaptif olarak hesaba katmaktadır. MobileNet-v2'deki düşük parametre yükü sayesinde bu adaptif güncellemeler hemen her katmanda son derece isabetli olmakta ve hızlı yakınsama ortaya çıkmaktadır (Emmanuel Okewu ve arkadaşları, 2020). Dolayısıyla tüm veriyi hatasız sınıflandırmaya imkân tanıyan %100'lük doğruluk, algoritmanın model ile kurduğu uyumun güçlü bir göstergesidir. Bu sonuç, özellikle verideki tüberküloz örneklerinin ayırt edici ipuçlarını çok kısa sürede istikrarlı şekilde kavrayabilmesiyle ilişkilidir.

SGDM, her ne kadar sabit bir öğrenme hızına bağlı olsa da geçmiş güncellemeleri belirli bir ölçüde hesaba katarak stabil bir optimizasyon süreci sunmaktadır. MobileNet-v2'nin katman geçişlerinde parametre güncellemelerini fazla zorlamaması ve momentum teriminin dalgalanmaları yumuşatması, modelin neredeyse kusursuz (%99.83) doğruluğa erişmesine katkı sağlamaktadır. Bu durum, özellikle yanlış negatif ve yanlış pozitif oranını düşük seviyede tutarak başarılı bir genelleme yeteneği kazandırmaktadır.

RMSProp, her bir parametre için farklı öğrenme oranı uygulamaktadır (Reham Elshamy ve arkadaşları, 2023). Bu yaklaşım, MobileNet-v2 gibi dar katmanlarda hızlı yakınsamayı desteklese de belirli katmanlarda gradyan güncellemelerinin aşırı duyarlılık göstermesine

yol açabilmektedir. Bu kısmi dengesizlik, modelin yüksek başarı düzeyini korumasına engel olmasa da (%98 doğruluk) Adam ve SGDM'nin ulaştığı mükemmele yakın seviyeyi tam olarak yakalamasını engellemektedir. Parametre uzayının görece kompakt ve organize yapısı, RMSProp'ın fazla dalgalanmasını görece düşük tutsa da, momentum odaklı ya da çift momentli adaptif algoritmalara göre bir miktar geride kalmasına sebep olmaktadır.

b) Veri Artırma Uygulanmadan Yapılan Deneyler

MobileNet-v2 modeli, veri artırma uygulanmadan yapılan deneylerde oldukça üstün sonuçlar sergilemiştir. RMSProp ile elde edilen %100 doğruluk ve %100 F1 skoru, modelin orijinal verinin tüm ayırt edici özelliklerini eksiksiz kavradığını göstermektedir. Adam ile yapılan eğitimde ise doğruluk %98.56, F1 skoru %100 olarak kaydedilmiş olup, burada ufak bir doğruluk kaybına rağmen modelin performansındaki genel mükemmellik dikkat çekmektedir. SGDM kullanılarak gerçekleştirilen deneyde ise %99.83 doğruluk ve %99.83 F1 skoru elde edilmiştir. Bu sonuçlar, MobileNet-v2'nin orijinal veri seti üzerinde optimizasyon algoritmalarının sunduğu güçlü yakınsama özellikleri sayesinde neredeyse kusursuz performans sunduğunu göstermektedir.

c) GAN ile Veri Artırma Uygulanarak Yapılmış Deneylerde Performans

GAN ile veri artırma kullanılarak yapılan deneylerde, MobileNet-v2 modelinde görece bir performans düşüşü gözlemlenmiştir. RMSProp ve Adam optimizasyon algoritmaları ile yapılan çalışmalarda model, yaklaşık %81.06 doğruluk ve %74.26 F1 skoru elde ederek, orijinal veri dağılımından sapmaların ve sentetik verideki gürültünün öğrenme sürecini olumsuz etkilediğini ortaya koymuştur. Buna karşın, SGDM kullanıldığında MobileNet-v2 %85.39 doğruluk ve %81.25 F1 skoru ile diğer algoritmalara göre daha iyi sonuçlar vermiştir. SGDM'nin momentum temelli yaklaşımı, GAN tarafından üretilen verinin getirdiği belirsizlik ve gürültüye karşı daha stabil bir yakınsama sağlayarak, optimizasyon sürecinde yaşanan performans kaybını telafi edebildiğini göstermektedir.

4.3.4. GoogleNet ve optimizasyon algoritmaları performans değerlendirmesi

a) Geleneksel veri artırma tekniği uygulanarak yapılmış deneylerde performans

GoogleNet modeli, RMSProp optimizasyon algoritması ile en düşük performansı göstermiş ve 30 yanlış negatif örnek rapor edilmiştir. Bu durum, modelin tüberküloz enfekte örnekleri tanımakta bir miktar zorlandığını göstermektedir. Adam ve SGDM

optimizasyon algoritmaları kullanıldığında modelin performansının arttığı görülmüştür olsa da diğer modellere kıyasla daha düşük bir doğruluk elde edilmiştir. Şekil 4.5’ te GoogleNet modelinin farklı optimizasyon algoritmaları ile performansı detaylı bir şekilde sunulmaktadır.

Output Class	H	270	0
	TI	30	300
		H	TI
		Target Class	

Output Class	H	299	13
	TI	1	287
		H	TI
		Target Class	

Output Class	H	300	12
	TI	0	288
		H	TI
		Target Class	

Şekil 4.5 GoogleNet için karmaşıklık matrisi (a) RMSProp, (b) Adam (c) SGDM

GoogleNet’in katmanlar arası veri akışını birden fazla filtre boyutuyla paralel işleyen yapısı, optimizasyon algoritmalarının model parametreleri üzerindeki etkisini belirgin ölçüde farklılaştırmaktadır (Riaz Ullah Khan ve arkadaşları, 2019). RMSProp, öğrenme oranını katmanlar veya filtreler arasında adaptif biçimde düzenlemeye çalışsa da bu paralel işlem yaklaşımı bazen güncellemelerin dengesiz dağılmasına yol açabilmektedir (Raniah Zaheer ve Humera Shaziya, 2019). Özellikle tüberküloz enfekte örneklerin doğru tanımlanmasında yeterli stabilite sağlayamadığında, bazı örnekler yanlış negatif veya yanlış pozitif olarak işaretlenmekte ve modelin genel doğruluğunu düşürmektedir. Bu nedenle RMSProp’ın GoogleNet üzerinde civarında kalan doğruluk oranı, diğer yöntemlerle kıyaslandığında daha düşük kalmaktadır.

Adam, birinci ve ikinci dereceden momentleri esas olarak güncellemeleri ayarladığından, özellikle derin ağlarda hızlı ve etkin bir yakınsama sağlayabilmektedir (M Reyad ve arkadaşları, 2023). GoogleNet gibi çok yönlü özellik çıkarımı yapan bir mimaride, Adam’ın adaptif mekanizması genel olarak daha tutarlı bir parametre düzenlemesi oluşturmakta ve %97.67 doğruluk elde etmesini sağlamaktadır. Ancak Adam’ın hassas ayar gerektiren adaptif yapısı, bazı durumlarda aşırı uyum ya da lokal minimuma takılma riski taşıyabilmektedir. SGDM ise sabit öğrenme oranıyla çalışırken, momentum sayesinde dalgalanmaları yumuşatmakta ve parametrelerin daha kararlı şekilde öğrenilmesine imkan tanımaktadır (U Simsekli ve arkadaşları, 2020). GoogleNet üzerinde %98 gibi yüksek bir doğrulukla sonuçlanan bu süreç, hem yanlış negatif hem de yanlış pozitif örneklerin sayısını azaltarak modelin genelleme yeteneğini güçlendirmiştir.

Bu da, GoogLeNet'in karmaşık katman yapısında dahi SGDM'nin dengeli güncelleme yaklaşımının avantajlarını ortaya koymaktadır.

b) Veri Artırma Uygulanmadan Yapılan Deneyler

GoogLeNet, veri artırma uygulanmadan yapılan deneylerde RMSProp ile %98.56 doğruluk ve %98.56 F1-skoru elde ederken Adam ve SGDM ile eğitimde %100 doğruluk ve F1-skoru kaydedilmiştir. Bu sonuçlar, orijinal veri setinin tüm ayırt edici özelliklerinin model tarafından neredeyse eksiksiz kavrandığını göstermektedir. Adam'ın adaptif öğrenme oranı mekanizması ve SGDM'nin momentum temelli güncelleme stratejisi, modelin verinin yapısal ve dokusal özelliklerini en iyi şekilde öğrenmesine olanak tanımış, RMSProp ise hafif bir sapma göstermiştir.

c) GAN ile Veri Artırma Uygulanarak Yapılmış Deneylerde Performans

GAN ile veri artırma kullanılarak yapılan deneylerde, GoogLeNet modelinde görece performans kaybı gözlemlenmiştir; RMSProp %81.87 doğruluk ve %75.64 F1-skoru, Adam %84.17 doğruluk ve %79.37 F1-skoru, SGDM ise %81.46 doğruluk ve %74.95 F1-skoru ile sonuçlanmıştır. Bu durum, GAN tarafından üretilen verilerin orijinal veri setinin karmaşık dağılımını tam olarak yansıtamamasından kaynaklanmaktadır. Adam, adaptif öğrenme mekanizması sayesinde diğer algoritmalarla kıyasla nispeten daha yüksek performans sergilerken, hem RMSProp hem de SGDM, GAN verilerindeki gürültü ve yapaylık nedeniyle benzer ve düşük sonuçlar vermiştir. Böylece, GoogLeNet'in GAN ile artırılmış veri üzerinde, optimizasyon algoritmalarının sunduğu avantajlar büyük ölçüde zayıflamış ve modelin genelleme yeteneğinde bir düşüş meydana gelmiştir.

4.3.5. EfficientNet-b0 ve Optimizasyon Algoritmaları Performans Değerlendirmesi

a) Geleneksel veri artırma tekniği uygulanarak yapılmış deneylerde performans

EfficientNet-b0 modeli, RMSProp ve SGDM optimizasyon algoritmaları ile tüm örnekleri doğru bir şekilde sınıflandırmış ve mükemmel bir performans sergilemiştir. Şekil 4.6' da gösterilmiş olduğu gibi, bu optimizasyon algoritmaları ile model hiçbir yanlış sınıflandırma yapmamıştır. Adam optimizasyon algoritması ile de model yüksek bir doğruluk elde etmiş ancak sadece birkaç yanlış sınıflandırma gözlenmiştir. Bu sonuçlar, EfficientNet-b0 modelinin tüberküloz teşhisi için son derece uygun olduğunu ve farklı optimizasyon algoritmaları ile yüksek performans elde edebildiğini göstermektedir.

Output Class	H	300	0
	TI	0	300
		H	TI
		Target Class	

Output Class	H	300	3
	TI	0	297
		H	TI
		Target Class	

Output Class	H	300	0
	TI	0	300
		H	TI
		Target Class	

Şekil 4.6 EfficientNet-b0 için karmaşıklık matrisi (a) RMSProp, (b) Adam (c) SGDM

EfficientNet-b0, parametre kullanımındaki verimliliği sayesinde optimizasyon süreçlerinde istikrarlı bir yakınsama sağlayabilecek bir yapıya sahiptir. Deneysel sonuçlar, modelin hem RMSProp hem de SGDM algoritmalarıyla herhangi bir yanlış sınıflandırma yapmadan tüm örnekleri doğru etiketlediğini göstermektedir. RMSProp, özellikle EfficientNet mimarilerinde önerilen bir yaklaşım olarak bilinmektedir (Rachmad Aeri ve arkadaşları, 2024); her bir katmandaki öğrenme oranlarını o katmanın gradyan büyüklüğüne göre ayrı ayrı uyarlaması, karmaşık özellik uzayının dengeli bir biçimde öğrenilmesine imkan tanımaktadır (Derya Soydaner, 2020). Böylece model, tüberküloz enfekte dokuların kendine özgü ayrıntılarını ve sağlıklı örneklerin genel yapısal desenlerini kusursuz biçimde kavrayarak yüksek genelleme başarısına ulaşmaktadır. SGDM ise, sabit öğrenme oranına rağmen momentum sayesinde gradyan dalgalanmalarını yumuşatmakta ve modelin parametre güncellemelerini pürüzsüz bir şekilde yönlendirmektedir (U Simsekli ve arkadaşları, 2020). Bu yaklaşım, EfficientNet-b0 gibi verimlilik odaklı bir mimaride dahi tam doğruluk seviyesine çıkılabildiğini göstermektedir.


Adam, adaptif öğrenme oranını ve moment terimlerini bir arada kullanarak derin ağlarda oldukça hızlı yakınsama potansiyeline sahiptir (M Reyad ve arkadaşları, 2023); burada da yüksek bir doğruluk (%99.5) sağladığı görülmektedir. Ancak RMSProp ve SGDM'nin ulaştığı mükemmel yakın sonuçlarla kıyaslandığında bir miktar geride kalması, adaptif moment tahmininin EfficientNet-b0'nun optimize edilmiş katman yapısına her zaman tam uyum sağlayamayışından kaynaklanmaktadır. Bazı durumlarda Adam, hızlı ve agresif güncellemeler sebebiyle belirli örneklerde modele fazla güven aşılıp ufak yanılgılara kapı aralayabilmektedir. Yine de %99.5 doğruluk, bu yaklaşımın model üzerindeki genel etkililiğini ortaya koymakta ve EfficientNet-b0'nun farklı optimizasyon stratejileriyle de son derece tatmin edici sonuçlar verebildiğini göstermektedir.

b) Veri Artırma Uygulanmadan Yapılan Deneyler

EfficientNet-b0 modeli, veri artırma uygulanmadan gerçekleştirilen deneylerde RMSProp, Adam ve SGDM optimizasyon algoritmaları kullanıldığında %100 doğruluk ve %100 F1-skoru elde etmiştir. Bu sonuç, modelin orijinal veri setindeki ayırt edici özellikleri tam anlamıyla kavradığını göstermektedir. Tüm optimizasyon stratejilerinde elde edilen bu sonuç, EfficientNet-b0'nin mimarisinin, temiz ve yüksek kaliteli veri üzerinde oldukça etkin olduğunu ve optimizasyon algoritmaları arasında belirgin bir farklılık olmadığını ortaya koymaktadır.

c) GAN ile Veri Artırma Uygulanarak Yapılmış Deneylerde Performans

GAN ile üretilen veriler kullanıldığında EfficientNet-b0 modelinde görece performans düşüşü gözlemlenmiştir. RMSProp ve Adam ile yapılan deneylerde model, yaklaşık %81.06 doğruluk ve %74.26 F1-skoru ile sonuçlanmıştır. Bu durum, GAN tarafından oluşturulan verilerin orijinal veri dağılımından sapmalar göstermesi ve modelin kritik ayırt edici özellikleri yeterince öğrenememesine işaret etmektedir. Buna karşın, SGDM optimizasyon algoritması kullanıldığında model, %86.47 doğruluk ve %82.88 F1-skoru elde ederek diğer yöntemlere kıyasla daha iyi bir performans sergilemiştir. SGDM'nin momentum temelli yaklaşımı, GAN verilerindeki gürültü ve belirsizliklere karşı daha stabil bir yakınsama sağlayarak, optimizasyon sürecinde yaşanan olumsuz etkileri kısmen telafi edebilmiştir.




Şekil 4.7 ResNet-50 (sgdm) için kayıp grafiği

ResNet-50 mimarisinde SGDM ile gerçekleştirilen eğitim sürecinin kayıp grafiği, şekil 4.7' de verilmiştir. Bu grafik parametrelerin hızla etkili bir yakınsamaya doğru yönlendiğini ve eğitim istikrarının yüksek olduğunu göstermektedir. İlk iterasyonlarda kayıp değeri nispeten yüksektir; bu, ağıın henüz tüm ağırlıkları rastgele veya düşük düzeyde eğitilmiş parametrelerle başlatmış olmasından kaynaklanmaktadır. Ardışık mini-batch güncellemeleriyle birlikte, kayıp değeri oldukça hızlı bir düşüş sergilemektedir. Bu keskin azalma ResNet-50'nin residual bloklar sayesinde gradyanın etkin biçimde ağıın

derin katmanlarına iletilebilmesi ve momentum mekanizmasının ani dalgalanmaları yumuşatarak kararlı bir güncelleme süreci sağlamasıyla ilişkilidir (L Wen ve arkadaşları, 2020).

Grafikte gözlenen periyodik sıçramalar, tipik olarak mini-batch dağılımındaki farklılıklar veya öğrenme oranının yer yer gradyan yönüyle tam uyumlu olmamasından kaynaklanabilmektedir (U simsekli ve arkadaşları, 2019). Momentumun varlığı, bu dalgalanmaların uzun vadede azalarak kayıp eğrisinin genel eğilimini ciddi biçimde etkilememesini sağlamaktadır. Dolayısıyla geçici yükselmeler görüldüğünde bile eğri, kayıp değerinin düşük seviyelere çekildiği bir yörüngeyi korumaya devam edebilmektedir. Bu, ResNet-50 gibi derin bir mimaride bile SGDM'nin kararlı ve güvenilir bir optimizasyon sunduğuna işaret etmektedir.

Epoch'un sonuna doğru kayıp değerinin çok düşük bir seviyeye inmesi, modelin eğitim verisi üzerinde yüksek bir doğruluk elde ettiğini ve sınıflandırma görevinde hedeflediği özellikleri başarılı bir şekilde öğrendiğini göstermektedir. Residual katman yapısı, derinlik arttıkça ortaya çıkan gradyan kaybı problemini hafifletirken, momentumlu SGD de katmanlar arasındaki büyük parametre güncellemelerinin önüne geçerek daha tutarlı bir parametre uzayı araması yürütmektedir (M Liu ve arkadaşları, 2021). Sonuçta kayıp grafiğinin hemen hemen minimum düzeye yaklaşarak sabitlenmesi, eğitim işleminin istikrarlı bir yakınsamayla sonuçlandığını ve ağıın bu veri seti üzerinde model karmaşıklığına uygun bir çözüm uzayına eriştiğini göstermektedir.




Şekil 4.8 DarkNet-53 (sgdm) için kayıp grafiği

DarkNet-53 mimarisinde SGDM ile gerçekleştirilen eğitim sürecinin kayıp grafiği, şekil 4.8' de verilmiştir. DarkNet-53 derin katman dizilimi ve yoğun konvolüsyon blokları sayesinde veri içindeki karmaşık özellikleri keşfetmeye yönelik yüksek kapasiteye sahip bir mimaridir (J Terven ve DM Córdova, 2023). SGDM optimizasyon algoritması ile eğitilen modelin kayıp grafiği incelendiğinde, ilk aşamalarda kaybın hızlı bir şekilde düştüğü ardından daha uzun bir iyileşme sürecine yayılan dalgalı bir seyir izlediği gözlenmektedir. İlk iterasyonlarda gözlenen keskin azalma, ağıın başlangıç

parametrelerini hızla düzenleyerek veriye uyum sağlamasıyla ilişkilidir (LN Smith, 2018). Bu aşamada momentum faktörü, gradyanlardaki ani değişiklikleri kısmen yumuşatsa da DarkNet-53'ün yüksek parametre boyutu, mini-batch dağılımlarının çeşitliliği ve öğrenme oranının zaman zaman gradyan yönüyle uyuşmaması, geçici sıçramalara neden olabilmektedir.

Orta iterasyonlarda (yaklaşık 20–60 arası) görülen nispeten yüksek dalgalanmalar, ağır bazı konvolüsyon bloklarında öğrenme hızının veriye tam örtüşmemesinden ve farklı mini-batch örneklerinin model üzerinde farklı yönlerde gradyan oluşturmamasından kaynaklanabilmektedir. Ancak, momentum terimi geçmiş güncellemeleri de dikkate alarak bu dalgalanmaları uzun vadede stabilize edici bir etki göstermekte ve kaybın giderek düştüğü bir eğilim korunmaktadır (Eleni I. Vlahogianni ve arkadaşları, 2005). Grafikte 60. iterasyon sonrasında meydana gelen sivri pikler de benzer şekilde mini-batch bazlı bellek yetersizlikleri veya veri çeşitliliği nedeniyle ortaya çıkan yerel değişimleri yansıtmaktadır.

Son kısma doğru kaybın düşük seviyelere inmesi ve daha sınırlı dalgalanmalar görülmesi, DarkNet-53'ün tüberküloz ve sağlıklı et dokularını ayırt etmede temel özellikleri istikrarlı bir biçimde yakalamaya başladığını göstermektedir. Yüksek kapasiteli bir modelin bu şekilde yakınsama eğilimini sürdürmesi, SGDM'nin istikrarlı güncelleme özelliğiyle yakından ilişkilidir. Momentum, derin katmanlar arasındaki parametre güncellemelerini tutarlı bir yörüngede yönlendirerek performansın lokal minimumlara takılmadan gelişmesine katkı sağlamaktadır (Tang Shenghao ve arkadaşları, 2018). Böylece, dalgalanmaların hala varlığını sürdürmesine karşın genel eğilimin düzenli bir azalma göstermesi, DarkNet-53'ün veriye uyum sağladığını ve yüksek bir genelleme kapasitesine doğru ilerlediğini işaret etmektedir.




Şekil 4.9 MobileNet-v2 (Adam) için kayıp grafiği

MobileNet-v2 mimarisinde Adam ile gerçekleştirilen eğitim sürecinin kayıp grafiği, şekil 4.9' da verilmiştir. Adam optimizasyon algoritması altında gösterdiği kayıp eğrisi,

modelin başlangıç aşamalarında son derece hızlı bir öğrenme performansı sergilediğini ve ardından dalgalı bir süreç üzerinden istikrarlı bir yakınsamaya yöneldiğini göstermektedir. Başlangıç iterasyonlarında kayıp değerinde keskin bir azalma görülmesi, Adam algoritmasının adaptif öğrenme oranları ve moment tahminleri sayesinde parametrelerin başlangıç koşullarından hızla sıyrılarak veri setindeki ayırt edici özelliklere uyum sağlamasıyla ilişkilidir. Özellikle MobileNet-v2 gibi hafif bir mimaride az sayıda parametreyle etkileşime giren Adam'ın adaptif yapısı, gradyan bilgi akışını etkin biçimde yöneterek sınıflandırmayı erken dönemde iyileştirmektedir (Ke Dong ve arkadaşları, 2020).

Bununla birlikte, grafik boyunca zaman zaman rastlanan yüksek pikler, mini-batch içeriğinin çeşitlenmesi veya modelin belirli ara katmanlarında parametre güncellemelerinin aşırı duyarlılık kazanmasından kaynaklanabilmektedir. Adam, momentum ve adaptif öğrenme oranlarını bir arada kullanarak bu dalgalanmaların büyümesini çoğu zaman önleyebilmektedir (M Reyad ve arkadaşları, 2023); ancak bazı durumlarda sınırlı sayıda örnek üzerinden hesaplanan anlık gradyanlar modelde geçici sıçramalara neden olabilmektedir (P Glasserman, 1990). MobilNet-v2'nin verimli katman tasarımı ve Adam'ın hızlı adaptasyon kabiliyeti sayesinde, bu pikin ardından kayıp değeri hızla toparlanabilmektedir ve genel trendin aşağı yönlü seyrini sürdürmektedir.

İlerleyen iterasyonlarda kaybın giderek düşük seviyelerde seyretmesi, modelin tüberküloz enfekte et dokularını sağlıklı dokulardan ayıran temel özellikleri büyük ölçüde öğrenmiş olduğunu göstermektedir. Ayrıca, grafik üzerinde yer yer beliren dalgalanmaların giderek sönümlenmesi ve ortalama kaybın oldukça düşük düzeyde sonlanması ise Adam'ın MobileNet-v2 mimarisinde veriyi aşırı uyum riskine kapılmadan hızlı ve etkin şekilde öğrenebilmesini yansıtmaktadır. Sonuç olarak, eğitim sürecinin final aşamasında kaybın istikrarlı biçimde minimal değerlere ulaşması, modelin yüksek doğrulukla tüberküloz teşhisi yapma kapasitesini doğrular niteliktedir.




Şekil 4.10 GoogleNet (sgdm) için kayıp grafiği

GoogleNet mimarisinin SGDM algoritmasıyla eğitildiği kayıp grafiği şekil 4.10’ da verilmiştir. Bu grafik modelin erken safhalarda hızla iyileştiğini ancak belirli bir süre boyunca kısmi dalgalanmalar ve sıçramalar yaşadığını göstermektedir. İlk iterasyonlarda gözlenen yüksek kayıp değerinin kısa sürede düşmesi, momentumlu güncellemelerin derin katmanlarda hızlı bir adaptasyona imkân sağlamasıyla ilişkilidir (Utku Can Aytaç ve arkadaşları, 2022). GoogleNet’in “inception blokları” şeklinde çok yönlü veri işleme yaklaşımı, farklı ölçeklerdeki filtreleri paralel kullanarak geniş bir özellik aralığı araştırmaktadır; bu da, eğitimin ilk kısımlarında modelin parametre uzayını çabuk tarayabilmesine destek olmaktadır (G Litjens ve arkadaşları, 2017)

Grafik boyunca görülen periyodik dalgalanmalar, mini-batch düzeyinde gradyanların farklı yönlerde dağılması ve her bir inception blok içindeki alt filtrelerin farklı özellikleri ön plana çıkarması sonucunda ortaya çıkabilmektedir. SGDM, önceki iterasyonlarda hesaplanan momentumu da devreye sokarak bu dalgalanmaların uzun vadede ciddi bir sapma yaratmasını engellemektedir. Nitekim yaklaşık 20. iterasyondan sonra kayıp değerinin sıklıkla 0.2 ve altı seviyelere çekilmesi, modelin veriyle başarılı bir şekilde uyum sağladığını göstermektedir. Derin mimarilerde momentum, özellikle çoklu filtre operasyonlarında lokal minimum veya keskin sapmalara hapsolmayı önleyerek, kaybın toplamda istikrarlı biçimde azalmasını sağlamaktadır (S Tang ve arkadaşları, 2018).

Sonraki iterasyonlarda, bazı sıçramalar görülse de bunların ortalama kaybı belirgin biçimde yükseltmediği ve kaybın düşük seviyelerde konumlandığı gözlemlenmektedir. Bu da GoogleNet’in SGDM eşliğinde, tüberküloz enfekte ve sağlıklı örnekler arasındaki ayırt edici ipuçlarını öğrenmekte istikrarlı bir başarı sergilediğine işaret etmektedir. Sona doğru kaybın neredeyse sabit bir plato çizmesi, modelin artık yüksek doğruluk sağlayacak şekilde yakınsamaya ulaştığını ve eğitim sürecinin genel olarak kararlı bir aşamaya girdiğini göstermektedir.



Şekil 4.11 EfficientNet-b0 (sgdm) için kayıp grafiği



Şekil 4.12 Kayıp grafikleri için göstergeler

EfficientNet-b0'nun SGDM eşliğinde gösterdiği kayıp eğrisi şekil 4.11'de verilmiştir. Bu grafik, mimarinin verimlilik odaklı tasarımının ve momentumlu güncelleme mekanizmasının uyumlu bir şekilde çalıştığını ortaya koymaktadır. Eğitimin ilk iterasyonlarında gözlenen yüksek kayıp değerinin hızla azalması, modelin başlangıç parametrelerini veri setinin ayırt edici özellikleri doğrultusunda yeniden yapılandırıldığını ve tüberküloz ile sağlıklı et dokuları arasındaki farklılıkları hızla öğrenmeye başladığını göstermektedir. Bu hızlı başlangıcın ardından kayıp değeri azalan ve dalgalanmaları nispeten düşük seviyelerde seyreden bir yörünge izleyerek istikrarlı biçimde azalmaktadır.

Grafik boyunca zaman zaman ortaya çıkan pikler, momentumlu optimizasyon algoritmalarında sıkça görülen mini-batch kaynaklı dalgalanmaların tipik bir yansımasıdır (C Xing ve arkadaşları, 2018). Momentum, önceki iterasyonların güncellemelerini kümülatif şekilde dikkate aldığı için bu ani sıçramaların uzun vadede ciddi bir sapmaya neden olması engellenir (K Cheng ve arkadaşları, 2020). Bu sayede kayıp eğrisi, ortalama olarak sürekli bir düşüş trendini korur. Özellikle yaklaşık 40–60. iterasyonlar arasında gözlenen nispeten düşük dalgalanmalar, EfficientNet-b0'ın parametrik verimliliğinin ve SGDM'nin sabit öğrenme oranını moment terimiyle destekleyen yaklaşımının istikrarlı yakınsamayı birlikte mümkün kıldığını göstermektedir (R Wang ve arkadaşları, 2023).

60. iterasyondan itibaren kaybın giderek daha düşük düzeylerde seyretmesi, modelin veri setini büyük ölçüde öğrendiğini ve her mini-batch sonrası parametre güncellemelerinin daha ince ayarlar hâline geldiğini işaret etmektedir. Eğrinin son kısımlarında düşük seviyede seyreden ve geçici sıçramalar dışında genel anlamda düşme trendine yakın duran kayıp değeri, EfficientNet-b0 mimarisinin tüberkülozla enfekte et dokularının kendine özgü özelliklerini yakalamada yüksek kapasiteye sahip olduğunu ve SGDM'nin güçlü bir genelleme performansına katkı sunduğunu ortaya koymaktadır. Bu bütüncül bakışla değerlendirildiğinde kayıp grafiği modelin hem hızlı hem de sağlam bir biçimde yakınsadığını ve nihayetinde sınıflandırma başarısını maksimize edecek koşullara ulaştığını göstermektedir.

BÖLÜM 5. SONUÇ VE ÖNERİLER

Bu çalışma kapsamında, bTB tespitinde derin öğrenme tabanlı modellerin etkinliği detaylı olarak değerlendirilmiş ve yüksek doğruluk oranlarına ulaşılmıştır. Elde edilen sonuçlar, hayvan kaynaklı gıda ürünlerinin güvenliği ve halk sağlığını koruma açısından önemli bir potansiyele işaret etmektedir. İnternet kaynaklı görüntülerin ve veri artırma tekniklerinin kullanıldığı veri seti üzerinde yapılan deneysel analizler, derin öğrenme mimarilerinin bTB enfeksiyonuna sahip et ürünlerini sağlıklı dokulardan ayırt etmede hem hızlı hem de genellikle yüksek isabetle çalışabildiğini göstermiştir. Bu yaklaşım, gıda güvenliği denetim süreçlerinin otomasyonunda ve veteriner hekimlik uygulamalarında kritik bir katkı sunabilecek niteliktedir.

Özellikle derin mimarilerin, mezbahalarda veya veteriner kliniklerinde alınan et örneklerinin patolojik durumlarını hızlı biçimde sınıflandırabilmesi, tüberkülozun yayılmasını önlemeye ve halk sağlığını korumaya yönelik bir erken uyarı mekanizması işlevi görmektedir. Ancak bu çalışmanın, internet kaynaklı görüntülere ve veri artırma yöntemlerine dayalı bir veri seti kullanması yerine, gerçek saha koşullarında elde edilen et örneklerinin kullanılması tercih edilebilir. Gerçek dünyadan elde edilecek yüksek kaliteli, etiketlenmiş veri setleriyle eğitilen modeller, gelecekte daha geniş coğrafi ve genetik çeşitlilikteki sığır popülasyonları üzerinde de başarıyla uygulanabilir ve böylece tüberküloz başta olmak üzere hayvan kaynaklı diğer patojenlerin erken tespiti için yol gösterici olabilir. Sonuçlar, hem akademik çalışmalara hem de sektördeki uygulamalara ışık tutacak kapsamdadır ve bu yöntemlerin ölçeklenebilir, ekonomik ve sürdürülebilir yapıda hayata geçirilmesi hedeflenmektedir.

Öneriler:

Gerçek mezbaha ve laboratuvar koşullarından toplanan yüksek kaliteli örnekler ile veri setleri genişletilmelidir.

Modellerin farklı hayvansal hastalıklar için de uygulanabilirliği araştırılmalıdır.

Gıda güvenliđi denetim srelerine yapay zeka temelli sistemlerin entegrasyonu teřvik edilmelidir.

Ekonomik srdrlebilirlik ve operasyonel verimlilik analizleri yaplarak sektrle iř birliđi artırlmaldr.

retim ve denetim srelerine ynelik leklenebilir ve kullanıcı dostu yazılım altyapıları tasarlanmaldr.



KAYNAKÇA

- Abd El-Ghany, S., Mahmood, M. A., Abd El-Aziz, A. A. (2024). Adaptive Dynamic Learning Rate Optimization Technique for Colorectal Cancer Diagnosis Based on Histopathological Image Using EfficientNet-B0 Deep Learning Model, *Electronics*, 13(16), 3126.
- Abdulkadimov, R., Lyakhov, P., Nagornov, N. (2023). Survey of optimization algorithms in modern neural networks, *Mathematics*, 11(11), 2466.
- Afzal, S., Maqsood, M., Nazir, F., Khan, U., Aadil, F. (2019). A data augmentation-based framework to handle class imbalance problem for Alzheimer's stage detection, *IEEE*.
- Aggarwal, C. C. (2018). *Neural networks and deep learning (Vol. 10, No. 978, p. 3)*. Cham, Springer.
- Akhtar, N., & Ragavendran, U. (2020). Interpretation of intelligence in CNN-pooling processes: a methodological survey, *Neural Computing and Applications*, 32(3), 879-898.
- Allaire, S., Kim, J. J., Breen, S. L., Jaffray, D. A., & Pekar, V. (2008, Haziran). Full orientation invariance and improved feature selectivity of 3D SIFT with application to medical image analysis, *2008 IEEE computer society conference on computer vision and pattern recognition workshops*, 1-8, IEEE.
- Anand, R., Lakshmi, S. V., Pandey, D., & Pandey, B. K. (2024). An enhanced ResNet-50 deep learning model for arrhythmia detection using electrocardiogram biomedical indicators, *Evolving Systems*, 15(1), 83-97.
- Anthimopoulos, M., Christodoulidis, S., Ebner, L., Christe, A., & Mougiakakou, S. (2016). Lung pattern classification for interstitial lung diseases using a deep convolutional neural network, *IEEE Transactions on Medical Imaging*, 35, 1207–1216, <https://doi.org/10.1109/TMI.2016.2535865>.
- Aytaç, U. C., Güneş, A., & Ajlouni, N. (2022). A novel adaptive momentum method for medical image classification using convolutional neural network, *BMC Medical Imaging*, 22(1), 34.
- Ayyalasomayajula, M. M. T., & Ayyalasomayajula, S. (2021). Proactive Scaling Strategies for Cost-Efficient Hyperparameter Optimization in Cloud-Based Machine Learning Models: A Comprehensive Review, *ESP Journal of Engineering & Technology Advancements (ESP JETA)*, 1(2), 42-56.
- Baione, F., Biancalana, D., & De Angelis, P. (2021). An application of Sigmoid and Double-Sigmoid functions for dynamic policyholder behaviour, *Decisions in Economics and Finance*, 44, 5-22.
- Bello, I., Fedus, W., Du, X., Cubuk, E. D., Srinivas, A., Lin, T. Y., et al. (2021). Revisiting resnets: Improved training and scaling strategies, *Advances in Neural Information Processing Systems*, 34, 22614-22627.
- Bhakta, S., Nandi, U., Si, T., Ghosal, S. K., Changdar, C., & Pal, R. K. (2023). DiffMoment: an adaptive optimization technique for convolutional neural network, *Applied Intelligence*, 53(13), 16844-16858.

- Bieder, F., Sandkühler, R., & Cattin, P. C. (2021). Comparison of methods generalizing max-and average-pooling, arXiv preprint arXiv:2103.01746.
- Bischl, B., Binder, M., Lang, M., Pielok, T., Richter, J., Coors, S., et al. (2023). Hyperparameter optimization: Foundations, algorithms, best practices, and open challenges, *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 13(2), e1484.
- Bognár, L., & Fauszt, T. (2022). Factors and conditions that affect the goodness of machine learning models for predicting the success of learning, *Computers and Education: Artificial Intelligence*, 3, 100100.
- Bottou, L. (2010). Large-scale machine learning with stochastic gradient descent, *Proceedings of COMPSTAT'2010: 19th International Conference on Computational Statistics Paris France, August 22-27, 2010 Keynote, Invited and Contributed Papers*, 177-186, Physica-Verlag HD.
- Chen, Y., Jiang, H., Li, C., Jia, X., & Ghamisi, P. (2016). Deep feature extraction and classification of hyperspectral images based on convolutional neural networks, *IEEE Transactions on Geoscience and Remote Sensing*, 54(10), 6232-6251.
- Chen, Z., Badrinarayanan, V., Lee, C. Y., & Rabinovich, A. (2018, Temmuz). Gradnorm: Gradient normalization for adaptive loss balancing in deep multitask networks, *International Conference on Machine Learning*, 794-803, PMLR.
- Cheng, K., Tao, F., Zhan, Y., Li, M., & Li, K. (2020). Hierarchical attributes learning for pedestrian re-identification via parallel stochastic gradient descent combined with momentum correction and adaptive learning rate, *Neural Computing and Applications*, 32, 5695-5712.
- Chollet, F. (2017). Xception: Deep learning with depthwise separable convolutions, *In Proceedings of the IEEE conference on computer vision and pattern recognition*, 1251-1258.
- Chu, Y., & You, F. (2012). Integration of scheduling and control with online closed-loop implementation: Fast computational strategy and large-scale global optimization algorithm, *Computers & Chemical Engineering*, 47, 248-268.
- Cong, S., & Zhou, Y. (2023). A review of convolutional neural network architectures and their optimizations, *Artificial Intelligence Review*, 56(3), 1905-1969.
- Das, D., Avancha, S., Mudigere, D., Vaidynathan, K., Sridharan, S., Kalamkar, D., et al. (2016). Distributed deep learning using synchronous stochastic gradient descent, arXiv preprint arXiv:1602.06709.
- Datta, L. (2020). A survey on activation functions and their relation with xavier and he normal initialization, arXiv preprint arXiv:2004.06632.
- Deepak, G. D., Bhat, S. K., & Gupta, A. (2025). Improved CNN architecture for automated classification of skin diseases, *Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization*, 13(1), 2420727.
- Défossez, A., Bottou, L., Bach, F., & Usunier, N. (2020). A simple convergence proof of adam and adagrad, arXiv preprint arXiv:2003.02395.
- Dhillon, A., & Verma, G. K. (2020). Convolutional neural network: a review of models, methodologies and applications to object detection, *Progress in Artificial Intelligence*, 9(2), 85-112.
- Dogo, E. M., Afolabi, O. J., Nwulu, N. I., Twala, B., & Aigbavboa, C. O. (2018, Aralık). A comparative analysis of gradient descent-based optimization algorithms on convolutional neural networks, *2018 International Conference on Computational Techniques, Electronics and Mechanical Systems (CTEMS)*, 92-99, IEEE.

- Dong, K., Zhou, C., Ruan, Y., & Li, Y. (2020, Aralık). MobileNetV2 model for image classification, *2020 2nd International Conference on Information Technology and Computer Application (ITCA)*, 476-480, IEEE.
- Dünya Sağlık Örgütü (World Health Organization, WHO) (2020). World Health Organization Global Tuberculosis Report 2020, <http://apps.who.int/iris> (Erişim Tarihi: 3 Temmuz 2022).
- Elshamy, R., Abu-Elnasr, O., Elhoseny, M., & Elmougy, S. (2023). Improving the efficiency of RMSProp optimizer by utilizing Nesterov in deep learning, *Scientific Reports*, 13(1), 8814.
- Evci, U. (2018). Detecting dead weights and units in neural networks, arXiv preprint arXiv:1806.06068.
- Glasserman, P. (1990). *Gradient estimation via perturbation analysis (Vol. 116)*, Springer Science & Business Media.
- Grosse, R., Johnson, M. K., Adelson, E. H., & Freeman, W. T. (2009, Eylül). Ground truth dataset and baseline evaluations for intrinsic image algorithms, *2009 IEEE 12th International Conference on Computer Vision*, 2335-2342, IEEE.
- Guo, R., Passi, K., & Jain, C. K. (2020). Tuberculosis diagnostics and localization in chest X-rays via deep learning models, *Frontiers in Artificial Intelligence*, 3, 583427.
- Habib, G., & Qureshi, S. (2022). Optimization and acceleration of convolutional neural networks: A survey, *Journal of King Saud University-Computer and Information Sciences*, 34(7), 4244-4268.
- Hand, D. J., Christen, P., & Kirielle, N. (2021). F*: an interpretable transformation of the F-measure, *Machine Learning*, 110(3), 451-456.
- He, K., & Sun, J. (2015). Convolutional neural networks at constrained time cost, *In Proceedings of the IEEE conference on computer vision and pattern recognition*, 5353-5360.
- Heo, B., Chun, S., Oh, S. J., Han, D., Yun, S., Kim, G., et al. (2020). AdamP: Slowing down the slowdown for momentum optimizers on scale-invariant weights, arXiv preprint arXiv:2006.08217.
- Hoos, H. (Ed.). (1999). *Stochastic local search-methods, models, applications*, IOS Press.
- Hosna, A., Merry, E., Gyalmo, J., Alom, Z., Aung, Z., & Azim, M. A. (2022). Transfer learning: a friendly introduction, *Journal of Big Data*, 9(1), 102.
- Hu, Z., Zhang, J., & Ge, Y. (2021). Handling vanishing gradient problem using artificial derivative, *IEEE Access*, 9, 22371-22377.
- Hussain, Z., Gimenez, F., Yi, D., & Rubin, D. (2017). Differential data augmentation techniques for medical imaging classification tasks, *AMIA Annual Symposium Proceedings (Vol. 2017, p. 979)*, American Medical Informatics Association.
- Ji, C., Wu, F., Zhu, Z., Chang, L. P., Liu, H., & Zhai, W. (2021). Memory-efficient deep learning inference with incremental weight loading and data layout reorganization on edge systems, *Journal of Systems Architecture*, 118, 102183.
- Kag, A., Zhang, Z., & Saligrama, V. (2020). Rnns incrementally evolving on an equilibrium manifold: A panacea for vanishing and exploding gradients?, *International Conference on Learning Representations*.
- Kamal, K. C., Yin, Z., Wu, M., & Wu, Z. (2019). Depthwise separable convolution architectures for plant disease classification, *Computers and Electronics in Agriculture*, 165, 104948.
- Ke, X., Zou, J., & Niu, Y. (2019). End-to-end automatic image annotation based on deep CNN and multi-label data augmentation, *IEEE Transactions on Multimedia*, 21(8), 2093-2106.

- Khan, R. U., Zhang, X., & Kumar, R. (2019). Analysis of ResNet and GoogleNet models for malware detection, *Journal of Computer Virology and Hacking Techniques*, 15, 29-37.
- Khairat, S., Feyzmahdavian, H. R., & Johansson, M. (2017, Aralık). Mini-batch gradient descent: Faster convergence under data sparsity, *2017 IEEE 56th Annual Conference on Decision and Control (CDC)*, 2880-2887, IEEE.
- Khosla, C., & Saini, B. S. (2020, Haziran). Enhancing performance of deep learning models with different data augmentation techniques: A survey, *2020 International Conference on Intelligent Engineering and Management (ICIEM)*, 79-85, IEEE.
- Kirtas, M., Passalis, N., & Tefas, A. (2024, Aralık). Multiplicative RMSprop Using Gradient Normalization for Learning Acceleration, *International Conference on Pattern Recognition*, 322-336, Cham: Springer Nature Switzerland.
- Kumar, A., Jain, R., & Dwivedi, R. (2022, Aralık). Weed detection in crops using lightweight EfficientNets, *International Conference on Communication and Intelligent Systems*, 149-162, Singapore: Springer Nature Singapore.
- Kyurkchiev, N., & Markov, S. (2015). *Sigmoid functions: some approximation and modelling aspects*, LAP LAMBERT Academic Publishing, Saarbrücken.
- Lakhani, P., & Sundaram, B. (2017). Deep learning at chest radiography: automated classification of pulmonary tuberculosis by using convolutional neural networks, *Radiology*, 284, 574–582, <https://doi.org/10.1148/radiol.2017162326>.
- Levin, R. I., Lieven, N. A. J., & Lowenberg, M. H. (2000). Measuring and improving neural network generalization for model updating, *Journal of Sound and Vibration*, 238(3), 401-424.
- Li, H., Zhao, R., & Wang, X. (2014). Highly efficient forward and backward propagation of convolutional neural networks for pixelwise classification, arXiv preprint arXiv:1412.4526.
- Li, L., Doroslovački, M., & Loew, M. H. (2020). Approximating the gradient of cross-entropy loss function, *IEEE Access*, 8, 111626-111635.
- Li, Z., Liu, F., Yang, W., Peng, S., & Zhou, J. (2021). A survey of convolutional neural networks: analysis, applications, and prospects, *IEEE Transactions on Neural Networks and Learning Systems*, 33(12), 6999-7019.
- Lin, T., Stich, S. U., Patel, K. K., & Jaggi, M. (2018). Don't use large mini-batches, use local sgd, arXiv preprint arXiv:1808.07217.
- Lin, Z., Zhang, S., Zhou, Y., & Wang, H. (tarih belirtilmemiş). Combining Sgdm and Adam in a Novel Approach, *Available at SSRN 4559736*.
- Liu, L., Jiang, H., He, P., Chen, W., Liu, X., Gao, J., & Han, J. (2019). On the variance of the adaptive learning rate and beyond, arXiv preprint arXiv:1908.03265.
- Liu, M., Chen, L., Du, X., Jin, L., & Shang, M. (2021). Activated gradients for deep neural networks, *IEEE Transactions on Neural Networks and Learning Systems*, 34(4), 2156-2168.
- Liu, M., Yao, D., Liu, Z., Guo, J., & Chen, J. (2023). An improved Adam optimization algorithm combining adaptive coefficients and composite gradients based on randomized block coordinate descent, *Computational Intelligence and Neuroscience*, 2023(1), 4765891.
- Liu, W., Principe, J. C., & Haykin, S. (2011). *Kernel adaptive filtering: a comprehensive introduction*, John Wiley & Sons.
- Liu, Y. H. (2018, Eylül). Feature extraction and image recognition with convolutional neural networks, *Journal of Physics: Conference Series* (Vol. 1087, p. 062032), IOP Publishing.

- Lizhen, W., Yifan, Z., Gang, W., & Xiaohong, H. (2022). A novel short-term load forecasting method based on mini-batch stochastic gradient descent regression model, *Electric Power Systems Research*, 211, 108226.
- Luo, Z. Q. (1991). On the convergence of the LMS algorithm with adaptive learning rate for linear feedforward networks, *Neural Computation*, 3(2), 226-245.
- Mascarenhas, S., & Agarwal, M. (2021, Kasım). A comparison between VGG16, VGG19 and ResNet50 architecture frameworks for Image Classification, *2021 International conference on disruptive technologies for multi-disciplinary research and applications (CENTCON)* (Vol. 1, 96-99), IEEE.
- Masters, D., & Luschi, C. (2018). Revisiting small batch training for deep neural networks, arXiv preprint arXiv:1804.07612.
- Menon, A., Mehrotra, K., Mohan, C. K., & Ranka, S. (1996). Characterization of a class of sigmoid functions with applications to neural networks, *Neural Networks*, 9(5), 819-835.
- Michele, A., Colin, V., & Santika, D. D. (2019). Mobilenet convolutional neural networks and support vector machines for palmprint recognition, *Procedia Computer Science*, 157, 110-117.
- Mitra, M., & Roy, S. (2023). Advancing COVID-19 Diagnosis with CNNs: An Empirical Study of Learning Rates and Optimization Strategies, *Intelligent Control and Automation*, 14(4), 45-78.
- Oğuz, A., & Ertuğrul, Ö. F. (2023). Determining the fullness of garbage containers by deep learning, *Expert Systems with Applications*, 217, 119544.
- Okewu, E., Misra, S., & Lius, F. S. (2020). Parameter tuning using adaptive moment estimation in deep learning neural networks, *Science and Its Applications-ICCSA 2020*.
- Pang, T., Xu, K., Dong, Y., Du, C., Chen, N., & Zhu, J. (2019). Rethinking softmax cross-entropy loss for adversarial robustness, arXiv preprint arXiv:1905.10626.
- Pasa, F., Golkov, V., Pfeiffer, F., Cremers, D., & Pfeiffer, D. (2019). Efficient deep network architectures for fast chest X-ray tuberculosis screening and visualization, *Scientific Reports*, 9, 6268, <https://doi.org/10.1038/s41598-019-42557-4>.
- Pawluszek-Filipiak, K., & Borkowski, A. (2020). On the importance of train-test split ratio of datasets in automatic landslide detection by supervised classification, *Remote Sensing*, 12(18), 3054.
- Platt, J. (1999). Probabilistic outputs for support vector machines and comparisons to regularized likelihood methods, *Advances in large margin classifiers*, 10(3), 61-74.
- Rachmad, A., Hutagalung, J., Hapsari, D., Hernawati, S., Syarief, M., Rochman, E. M. S., & Asmara, Y. P. (2024). Deep Learning Optimization of the EfficienNet Architecture for Classification of Tuberculosis Bacteria, *Mathematical Modelling of Engineering Problems*, 11(10).
- Rahman, J. U., Zulfiqar, R., & Khan, A. (2024). SwishReLU: A unified approach to activation functions for enhanced deep neural networks performance, arXiv preprint arXiv:2407.08232
- Rajpurkar, P., Irvin, J., Zhu, K., Yang, B., Mehta, H., Duan, T., et al. (2018). Chexnet: Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning, arXiv: 1711.05225, <https://arxiv.org/abs/1711.05225>
- Reyad, M., Sarhan, A. M., & Arafa, M. (2023). A modified Adam algorithm for deep neural network optimization, *Neural Computing and Applications*, 35(23), 17095-17112.


- Rojas, R., & Rojas, R. (1996). The backpropagation algorithm, *Neural networks: a systematic introduction*, 149-182.
- Roy, S. K., Manna, S., Dubey, S. R., & Chaudhuri, B. B. (2022, Kasım). LiSHT: Non parametric linearly scaled hyperbolic tangent activation function for neural networks, *International Conference On Computer Vision And Image Processing*, 462-476, Cham: Springer Nature Switzerland.
- Rumelhart, D. E., Durbin, R., Golden, R., & Chauvin, Y. (2013). Backpropagation: The basic theory, *Backpropagation*, 1-34, Psychology Press.
- Schaul, T., Zhang, S., & LeCun, Y. (2013, Mayıs). No more pesky learning rates, *International Conference on Machine Learning*, 343-351, PMLR.
- Shariff, K. K. M., Zainuddin, S., & Ali, M. S. A. M. (2022, Mayıs). Detection of wet road surfaces from acoustic signals using scalogram and optimized AlexNet, *2022 IEEE 12th Symposium on Computer Applications & Industrial Electronics (ISCAIE)*, 159-163, IEEE.
- Sharma, N., Garg, N., Garg, B., Ranjan, S., & Goyal, P. (2023). Image Classification of Various Lung Diseases Using Transfer Learning and Machine Learning Techniques, *Available at SSRN 4628662*.
- Simsekli, U., Sagun, L., & Gurbuzbalaban, M. (2019, Mayıs). A tail-index analysis of stochastic gradient noise in deep neural networks, *International Conference on Machine Learning*, 5827-5837, PMLR.
- Simsekli, U., Zhu, L., Teh, Y. W., & Gurbuzbalaban, M. (2020, Kasım). Fractional underdamped langevin dynamics: Retargeting sgd with momentum under heavy-tailed gradient noise, *International conference on machine learning*, 8970-8980, PMLR.
- Siregar, S. P., & Wanto, A. (2017). Analysis of artificial neural network accuracy using backpropagation algorithm in predicting process (forecasting), *IJISTECH (International Journal of Information System and Technology)*, 1(1), 34-42.
- Smith, L. N. (2018). A disciplined approach to neural network hyper-parameters: Part 1-learning rate, batch size, momentum, and weight decay, *arXiv preprint arXiv:1803.09820*.
- Smith, S. L., & Le, Q. V. (2017). A bayesian perspective on generalization and stochastic gradient descent, *arXiv preprint arXiv:1710.06451*.
- Sola, J., & Sevilla, J. (1997). Importance of input data normalization for the application of neural networks to complex industrial problems, *IEEE Transactions on Nuclear Science*, 44(3), 1464-1468.
- Soydaner, D. (2020). A comparison of optimization algorithms for deep learning, *International Journal of Pattern Recognition and Artificial Intelligence*, 34(13), 2052013.
- Su, H., Jampani, V., Sun, D., Gallo, O., Learned-Miller, E., & Kautz, J. (2019). Pixel-adaptive convolutional neural networks, *In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 11166-11175.
- Szandała, T. (2021). Review and comparison of commonly used activation functions for deep neural networks, *Bio-inspired Neurocomputing*, 203-224.
- Sze, V., Chen, Y. H., Yang, T. J., & Emer, J. S. (2017). Efficient processing of deep neural networks: A tutorial and survey, *Proceedings of the IEEE*, 105(12), 2295-2329.
- Tamilarasi, R., & Gopinathan, S. (2021, Temmuz). Inception architecture for brain image classification, *Journal of Physics: Conference Series* (Vol. 1964, No. 7, p. 072022), IOP Publishing.

- Tan, M., & Le, Q. (2019, May15). Efficientnet: Rethinking model scaling for convolutional neural networks, *International Conference on Machine Learning*, 6105-6114, PMLR.
- Tang, S., Shen, C., Wang, D., Li, S., Huang, W., & Zhu, Z. (2018). Adaptive deep feature learning network with Nesterov momentum and its application to rotating machinery fault diagnosis, *Neurocomputing*, 305, 1-14.
- Tervonen, J., & Córdova, D. M. (2023). A comprehensive review of YOLO architectures in computer vision: From YOLOv1 to YOLOv8 and YOLO-NAS, *MDPI*, <https://www.mdpi.com/2504-4990/5/4/83>.
- Touchette, H. (2009). The large deviation approach to statistical mechanics, *Physics Reports*, 478(1-3), 1-69.
- Van Noord, N., & Postma, E. (2017). Learning scale-variant and scale-invariant features for deep image classification, *Pattern Recognition*, 61, 583-592.
- Wang, Q., Su, F., Dai, S., Lu, X., & Liu, Y. (2024). AdaGC: A Novel Adaptive Optimization Algorithm with Gradient Bias Correction, *Expert Systems with Applications*, 256, 124956.
- Wang, X., Qin, Y., Wang, Y., Xiang, S., & Chen, H. (2019). ReLTanh: An activation function with vanishing gradient resistance for SAE-based DNNs and its application to rotating machinery fault diagnosis, *Neurocomputing*, 363, 88-98.
- Wang, X. W., Shi, S. Z., Yao, X. J., Pei, J. B., Wang, Y. F., Yang, H. B., & Liu, D. Q. (2023). Automatic identification of seismic faults via integrating Residual Network-50 residual blocks and convolutional block attention modules, *Applied Geophysics*, 20(1), 20-35.
- Wei, H., Xie, R., Cheng, H., Feng, L., An, B., & Li, Y. (2022, Haziran). Mitigating neural network overconfidence with logit normalization, *International Conference on Machine Learning*, 23631-23644, PMLR.
- Weiss, J., Gibis, M., Schuh, V., & Salminen, H. (2010). Advances in ingredient and processing systems for meat and meat products, *Meat Science*, 86(1), 196-213.
- Wen, L., Li, X., & Gao, L. (2020). A transfer convolutional neural network for fault diagnosis based on ResNet-50, *Neural Computing and Applications*, 32(10), 6111-6124.
- Wilson, D. R., & Martinez, T. R. (2003). The general inefficiency of batch training for gradient descent learning, *Neural Networks*, 16(10), 1429-1451.
- Xie, X., Zhou, P., Li, H., Lin, Z., & Yan, S. (2024). Adan: Adaptive nesterov momentum algorithm for faster optimizing deep models, *IEEE Transactions on Pattern Analysis and Machine Intelligence*.
- Xing, C., Arpit, D., Tsirigotis, C., & Bengio, Y. (2018). A walk with sgd, arXiv preprint arXiv:1802.08770.
- Xu, D., Zhang, S., Zhang, H., & Mandic, D. P. (2021). Convergence of the RMSProp deep learning method with penalty for nonconvex optimization, *Neural Networks*, 139, 17-23.
- Yi, D., Ahn, J., & Ji, S. (2020). An effective optimization method for machine learning based on ADAM, *Applied Sciences*, 10(3), 1073.
- Yin, X., Goudriaan, J. A. N., Lantinga, E. A., Vos, J. A. N., & Spiertz, H. J. (2003). A flexible sigmoid function of determinate growth, *Annals of Botany*, 91(3), 361-371.
- Yu, H., Yang, L. T., Zhang, Q., Armstrong, D., & Deen, M. J. (2021). Convolutional neural networks for medical image analysis: state-of-the-art, comparisons, improvement and perspectives, *Neurocomputing*, 444, 92-110.


- Zaheer, R., & Shaziya, H. (2019, Ocak). A study of the optimization algorithms in deep learning, *2019 Third International Conference on Inventive Systems and Control (ICISC)*, 536-539, IEEE.
- Zamanlooy, B., & Mirhassani, M. (2013). Efficient VLSI implementation of neural networks with hyperbolic tangent activation function, *IEEE Transactions on Very Large Scale Integration (VLSI) Systems*, 22(1), 39-48.
- Zangana, H. M., Mohammed, A. K., & Mustafa, F. M. (2024). Advancements and Applications of Convolutional Neural Networks in Image Analysis: A Comprehensive Review, *Jurnal Ilmiah Computer Science*, 3(1), 16-29.
- Zhang, J. (2019). Gradient descent based optimization algorithms for deep learning models training, arXiv preprint arXiv:1903.03614.
- Zhang, J., He, T., Sra, S., & Jadbabaie, A. (2019). Why gradient clipping accelerates training: A theoretical justification for adaptivity, arXiv preprint arXiv:1905.11881.
- Zhang, X., Fan, M., & Hou, M. (2024). Mobilenet V3-transformer, a lightweight model for image caption, *International Journal of Computers and Applications*, 1-9.
- Zhu, P., Xu, Q., Hu, Q., Zhang, C., & Zhao, H. (2018). Multi-label feature selection with missing labels, *Pattern Recognition*, 74, 488-502.
- Zubair, S., Singha, A. K., Pathak, N., Sharma, N., Urooj, S., & Larguech, S. R. (2023). Performance Enhancement of Adaptive Neural Networks Based on Learning Rate, *Computers, Materials & Continua*, 74(1).

EKLER


EK A: Eğitim Grafikleri



(a)




(b)




(c)


Şekil A.1: ResNet-50 Eğitim Grafikleri: (a)SGDM. (b)Adam. (c)Rmsprop



(a)




(b)




(c)


Şekil A.2: GoogleNet Eğitim Grafikleri: (a)SGDM. (b)Adam. (c)Rmsprop



(a)




(b)




(c)


Şekil A.3: EfficientNet Eğitim Grafikleri: (a)SGDM. (b)Adam. (c)Rmsprop



(a)




(b)




(c)


Şekil A.4: DarkNet-53 Eğitim Grafikleri: (a)SGDM. (b)Adam. (c)Rmsprop



(a)



(b)



(c)

Şekil A.5: MobileNet-v2 Eğitim Grafikleri: (a)SGDM. (b)Adam. (c)Rmsprop