

**BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİYOMEDİKAL MÜHENDİSLİĞİ ANABİLİM DALI
BİYOMEDİKAL MÜHENDİSLİĞİ TEZLİ YÜKSEK LİSANS PROGRAMI**

**MAYMUN ÇİÇEĞİ HASTALIĞININ CİLT LEZYON GÖRÜNTÜLERİ
ÜZERİNDEN YAPAY ZEKÂ ALGORİTMALARI İLE
SINIFLANDIRILMASI**

HAZIRLAYAN

FIRAT BULAK

YÜKSEK LİSANS TEZİ

ANKARA- 2025

**BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİYOMEDİKAL MÜHENDİSLİĞİ ANABİLİM DALI
BİYOMEDİKAL MÜHENDİSLİĞİ TEZLİ YÜKSEK LİSANS PROGRAMI**

**MAYMUN ÇİÇEĞİ HASTALIĞININ CİLT LEZYON GÖRÜNTÜLERİ
ÜZERİNDEN YAPAY ZEKÂ ALGORİTMALARI İLE
SINIFLANDIRILMASI**

HAZIRLAYAN

FIRAT BULAK

YÜKSEK LİSANS TEZİ

TEZ DANIŞMANI

DR. ÖĞR. ÜYESİ ONUR KOÇAK

ANKARA- 2025

BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Biyomedikal Mühendisliği Anabilim Dalı Biyomedikal Mühendisliği Tezli Yüksek Lisans Programı çerçevesinde Fırat BULAK tarafından hazırlanan bu çalışma, aşağıdaki jüri tarafından Yüksek Lisans Tezi olarak kabul edilmiştir.

Tez Savunma Tarihi: 01 / 09 / 2025

Tez Adı: Maymun Çiçeği Hastalığının Cilt Lezyon Görüntüleri Üzerinden Yapay Zekâ Algoritmaları ile Sınıflandırılması

Tez Jüri Üyeleri (Unvanı, Adı - Soyadı, Kurumu)

İmza

Dr. Öğr. Üyesi Fevzi Aytaç DURMAZ İstinye Üniversitesi

Prof. Dr. Ziya TELATAR Başkent Üniversitesi

Dr. Öğr. Üyesi Onur KOÇAK Başkent Üniversitesi

ONAY

Prof. Dr. Dilek ÇÖKELİLER SERDAROĞLU

Fen Bilimleri Enstitüsü Müdürü

Tarih: ... / ... /

BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLER ENSTİTÜSÜ
YÜKSEK LİSANS TEZ ÇALIŞMASI ORJİNALLİK RAPORU

Tarih: 15 / 09 / 2025

Öğrencinin Adı, Soyadı: Fırat BULAK

Öğrencinin Numarası: 22320179

Anabilim Dalı: Biyomedikal Mühendisliği

Programı: Biyomedikal Mühendisliği Tezli Yüksek Lisans

Danışmanın Unvanı/Adı, Soyadı: Dr. Öğr. Üyesi Onur KOÇAK

Tez Başlığı: Maymun Çiçeği Hastalığının Cilt Lezyon Görüntüleri Üzerinden Yapay Zekâ Algoritmaları ile Sınıflandırılması

Yukarıda başlığı belirtilen Yüksek Lisans tez çalışmamın; Giriş, Ana Bölümler ve Sonuç Bölümünden oluşan, toplam 93 sayfalık kısmına ilişkin, 11 / 09 / 2025 tarihinde şahsım tarafından Turnitin adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı %6'dır. Uygulanan filtrelemeler:

1. Kaynakça hariç
2. Alıntılar hariç
3. Beş (5) kelimedenden daha az örtüşme içeren metin kısımları hariç

“Başkent Üniversitesi Enstitüleri Tez Çalışması Orijinallik Raporu Alınması ve Kullanılması Usul ve Esaslarını” inceledim ve bu uygulama esaslarında belirtilen azami benzerlik oranlarına tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Öğrenci İmzası:.....

ONAY

Tarih: 15 / 09 / 2025

Öğrenci Danışmanı:

Dr. Öğr. Üyesi Onur KOÇAK

.....

Bu tezi, sađlık hizmetlerinde alıřan ve lkemizin geleceęinde nemli yeri olan sađlık teknolojilerini geliřtiren tm mhendis, doktor ve sađlık profesyonellerine adıyorum.

Fırat BULAK

Ankara - 2025

TEŐEKKÜR

Bu tez alıőmasının her aőamasında beni ynlendiren, bilgi ve tecrbesiyle yolumu aydınlatan kıymetli hocam Sayın Dr. đr. yesi Onur KOAK'a en iten teőekkrlerimi ve saygılarımı sunarım.

Ayrıca, lisans ve yksek lisans eđitimim boyunca bilgi birikimleri, destekleri ve teővikleriyle beni daima motive eden Baőkent niversitesi Biyomedikal Mhendisliđi Blm'nn baőta Ana Bilim Dalı Blm Baőkanımız Sayın Prof. Dr. Ziya TELATAR olmak zere tm kıymetli đretim yelerine minnettarım.

Bugne dek bana koőulsuz sevgi ve destekleriyle g veren sevgili anneme, babama ve kız kardeőime sonsuz teőekkr ederim. Katkılarıyla bu alıőmanın oluőmasına zemin hazırlayan herkese gnlden teőekkr ederim.

ÖZET

Fırat BULAK

MAYMUN ÇİÇEĞİ HASTALIĞININ CİLT LEZYON GÖRÜNTÜLERİ ÜZERİNDEN YAPAY ZEKÂ ALGORİTMALARI İLE SINIFLANDIRILMASI

Başkent Üniversitesi Fen Bilimleri Enstitüsü

Biyomedikal Mühendisliği Anabilim Dalı

2025

Maymun çiçeği hastalığı, 2022 yılı itibariyle küresel salgın tehdidi haline gelmiş ve Dünya Sağlık Örgütü (DSÖ) önderliğinde ülkelerin salgınla mücadelede hızlı adım atmaları konusundan çalışmalar yürütülmüştür. Tanı sürecinde sıklıkla laboratuvar testleri tercih edilmektedir; ancak bulaş riski yüksek olduğundan yardımcı çözümlere de ihtiyaç vardır. Bu çalışmada, toplam 1259 cilt görüntüsünden oluşan iki sınıflı hibrit bir veri tabanı oluşturulmuştur. Maymun çiçeği ve maymun çiçeği olmayan cilt görüntülerinin sınıflandırılmasında, 8 adet önceden eğitilmiş derin öğrenme modeli kullanılmış ve yüksek performans gösteren DenseNet169, DenseNet201 ve Xception modellerinin özellik düzeyi yığılma topluluk öğrenmesi yaklaşımıyla ara katmanlarından elde edilen özellik vektörleri birleştirilerek daha iyi seviyede sınıflandırma yapabilen model geliştirilmiştir. Yeni model, test veri seti üzerinde %99.30 doğruluğa ulaşmıştır. Modelin sınıflandırma yaparken odaklandığı bölgeleri tespit etmek için de Gradyan Ağırlıklı Sınıf Aktivasyon Haritalandırma (Grad-CAM) kullanılmıştır. Bu çalışmayla, farklı model mimarilerinin güçlü yönleri kullanılarak geliştirilen yeni modellerin daha başarılı tahminleme yapabileceği gözlemlenmiştir.

ANAHTAR KELİMELEER: Maymun Çiçeği Hastalığı, Maymun Çiçeği Veri Seti, Yığılma Topluluk Öğrenmesi, Transfer Öğrenme, Gradyan Ağırlıklı Sınıf Aktivasyon Haritalandırma

ABSTRACT

Firat BULAK

CLASSIFICATION OF MONKEYPOX SKIN LESION IMAGES USING ARTIFICIAL INTELLIGENCE ALGORITHMS

Başkent University Institute of Science

Department of Biomedical Engineering

2025

Monkeypox disease emerged as a global pandemic threat as of 2022, prompting coordinated efforts under the leadership of the World Health Organization (WHO) for countries to take rapid action against the outbreak. Although laboratory tests are commonly preferred during the diagnostic process, due to the high risk of contagion, there is a need for supplementary solutions. In this study, a binary hybrid dataset consisting of a total of 1,259 skin images was created. For the classification of monkeypox and non-monkeypox skin images, 8 pre-trained deep learning models were utilized. Among them, DenseNet201, DenseNet169, and Xception, which demonstrated high performance, were used to extract features from their intermediate layers. These features were then combined using a feature-level stacking ensemble learning approach to develop a model capable of more accurate classification. The proposed model achieved an accuracy of 99.30% on the test dataset. Additionally, Gradient-weighted Class Activation Mapping (Grad-CAM) was employed to identify the regions the model focused on during classification. This study demonstrates that models developed by leveraging the strengths of different architectures can lead to more successful predictions.

KEYWORDS: Monkeypox Disease, Monkeypox Dataset, Stacking Ensemble Learning, Transfer Learning, Grad-CAM

İÇİNDEKİLER

TEŞEKKÜR	i
ÖZET.....	ii
ABSTRACT	iii
İÇİNDEKİLER.....	iv
TABLolar LİSTESİ.....	vi
ŞEKİLLER LİSTESİ	viii
SİMGELER VE KISALTMALAR LİSTESİ.....	x
1. GİRİŞ	1
1.1. Çalışmanın Amacı.....	3
1.2. Çalışmanın Bilime Katkısı	3
1.3. Çalışmanın Kapsamı.....	4
2. MAYMUN ÇİÇEĞİ HASTALIĞI VE TARİHÇESİ.....	5
3. MAYMUN ÇİÇEĞİ HASTALIĞI TEŞHİS YÖNTEMLERİ.....	8
3.1. Dolaylı Teşhis Yöntemleri	8
3.2. Doğrudan Teşhis Yöntemleri.....	8
3.3. Görüntü Tabanlı Teşhis Yönteminin Avantajı	8
4. LİTERATÜR ARAŞTIRMASI	9
5. MATERYAL VE YÖNTEM.....	15
5.1. Veri Setinin Hazırlanması	15
5.1.1. Veri setinin açık kaynak veritabanları üzerinden elde edilmesi	15
5.1.2. Duplike olan verilerin silinmesi.....	16
5.1.3. Görüntülerin png dönüşümü ve boyutlarının ayarlanması	17
5.1.4. Veri artırma işlemi	18
5.2. Derin Öğrenme	19
5.2.1. Denetimli öğrenme.....	22
5.2.2. Denetimsiz öğrenme	23
5.3. Yapay Sinir Ağları	23
5.3.1. Evrimsel sinir ağları.....	24
5.3.2. Aktivasyon fonksiyonları	28
5.3.3. Optimizasyon (Optimizer)	30

5.3.4. Tam bağlantılı katman	31
5.4. Çalışmada Yer Alan Modeller	32
5.4.1. Xception	32
5.4.2. Inception V3	34
5.4.3. MobileNet V2	35
5.4.4. DenseNet-121	36
5.4.5. DenseNet-169	37
5.4.6. DenseNet-201	37
5.4.7. VGG-16	38
5.4.8. VGG-19	38
5.4.9. Meta Model.....	39
5.5. Model Değerlendirmesinde Kullanılan Performans Metrikleri	41
5.5.1. Doğruluk (Accuracy)	41
5.5.2. Kesinlik (Precision).....	42
5.5.3. Duyarlılık (Recall)	42
5.5.4. F1 skoru (F1 Score)	42
5.5.5. Karışıklık matrisi (confusion matrix)	42
6. BULGULAR VE TARTIŞMA.....	43
6.1. VGG16 Modeli Deneysel Çıktılar & Analiz Sonuçları.....	45
6.2. VGG19 Modeli Deneysel Çıktılar & Analiz Sonuçları.....	50
6.3. DenseNet121 Modeli Deneysel Çıktılar & Analiz Sonuçları.....	55
6.4. DenseNet169 Modeli Deneysel Çıktılar & Analiz Sonuçları.....	60
6.5. DenseNet201 Modeli Deneysel Çıktılar & Analiz Sonuçları.....	65
6.6. Inceptionv3 Modeli Deneysel Çıktılar & Analiz Sonuçları.....	70
6.7. Xception Modeli Deneysel Çıktılar & Analiz Sonuçları.....	76
6.8. MobileNetv2 Modeli Deneysel Çıktılar & Analiz Sonuçları	81
6.9. Meta Model Deneysel Çıktılar & Analiz Sonuçları	86
7. LİTERATÜR KARŞILAŞTIRMASI.....	91
8.SONUÇ.....	92
9. ÖNERİ	94
KAYNAKLAR	95

TABLolar LİSTESİ

	Sayfa
Tablo 5.1. Veri Artırma Değerleri	18
Tablo 6.1. VGG16 Veri Dağılımı	45
Tablo 6.2. VGG16 Hiperparametre Değerleri	45
Tablo 6.3. VGG16 Sınıflandırıcı Performans Çıktıları.....	47
Tablo 6.4. VGG19 Veri Seti Yüzde Dağılımı	50
Tablo 6.5. VGG19 Hiperparametre Değerleri	51
Tablo 6.6. VGG19 Sınıflandırıcı Performans Çıktıları.....	52
Tablo 6.7. DenseNet121 Veri Dağılımı	55
Tablo 6.8. DenseNet121 Hiperparametre Değerleri	56
Tablo 6.9. DenseNet121 Sınıflandırıcı Performans Çıktıları	57
Tablo 6.10. DenseNet169 Veri Dağılımı	60
Tablo 6.11. Densenet169 Hiperparametre Değerleri	61
Tablo 6.12. DenseNet169 Sınıflandırıcı Performans Çıktıları	62
Tablo 6.13. DenseNet201 Veri Dağılımı	65
Tablo 6.14. DenseNet201 Hiperparametre Değerleri	65
Tablo 6.15. DenseNet201 Sınıflandırıcı Performans Çıktıları	67
Tablo 6.16. Inceptionv3 Veri Dağılımı.....	70
Tablo 6.17. Inceptionv3 Hiperparametre Değerleri	71
Tablo 6.18. Inceptionv3 Sınıflandırıcı Performans Çıktıları	73
Tablo 6.19. Xception Veri Dağılımı	76
Tablo 6.20. Xception Hiperparametre Değerleri	76
Tablo 6.21. Xception Sınıflandırıcı Performans Çıktıları.....	78
Tablo 6.22. MobileNetv2 Veri Dağılımı	81
Tablo 6.23. MobileNetv2 Hiperparametre Değerleri.....	81

Tablo 6.24. MobileNetv2 Sınıflandırıcı Performans Çıktıları	83
Tablo 6.25. Meta Model Veri Dağılımı	86
Tablo 6.26. Meta Model Hiperparametre Değerleri	87
Tablo 6.27. Meta Model Sınıflandırıcı Performans Çıktıları.....	88
Tablo 7.1. Literatür Karşılaştırması	91

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 2.1. Maymun Çiçeği İlk İnsan Vakası	6
Şekil 2.2. ABD Hastalık Vaka Bildirimi	6
Şekil 2.3. DSÖ Hastalık Genel Durumu	7
Şekil 5.1. Maymun Çiçeği ve Normal İnsan Görüntüleri	19
Şekil 5.2. Model Performansını Etkileyen Hususlar.....	21
Şekil 5.3. Denetimli Öğrenme Örneği	22
Şekil 5.4. Yapay Sinir Ağları.....	24
Şekil 5.5. Evrişimsel Sinir Ağları	26
Şekil 5.6. Maksimum Havuzlama İşlemi.....	27
Şekil 5.7. Ortalama Havuzlama İşlemi	28
Şekil 5.8. Tam Bağlantılı Katman Modeli.....	32
Şekil 5.9. Xception Mimarisi	33
Şekil 5.10. Inception V3 Mimarisi.....	35
Şekil 5.11. MobileNet V2 Mimarisi	36
Şekil 6.1. NVIDIA Tesla T4 GPU Özellikleri.....	43
Şekil 6.2. Google Colab Geliştirme Ortamı.....	44
Şekil 6.3. Çalışmada Kullanılan Veritabanı.....	44
Şekil 6.4. VGG16 Karışıklık Matrisi	48
Şekil 6.5. VGG16 Doğruluk Kayıp Grafikleri.....	49
Şekil 6.6. VGG16 Grad-CAM Analizi	50
Şekil 6.7. VGG19 Karışıklık Matrisi	53
Şekil 6.8. VGG19 Doğruluk Kayıp Grafikleri.....	54
Şekil 6.9. VGG19 Grad-CAM Analizi	54
Şekil 6.10. DenseNet121 Karışıklık Matrisi.....	58

Şekil 6.11. DenseNet121 Doğruluk ve Kayıp Grafikleri	59
Şekil 6.12. DenseNet121 Grad-CAM Analizi	59
Şekil 6.13. DenseNet169 Karışıklık Matrisi	63
Şekil 6.14. DenseNet169 Doğruluk ve Kayıp Grafikleri	64
Şekil 6.15. DenseNet169 Grad-CAM Analizi	64
Şekil 6.16. DenseNet201 Karışıklık Matrisi	68
Şekil 6.17. DenseNet201 Doğruluk Kayıp Grafikleri.....	69
Şekil 6.18. DenseNet201 Grad-CAM Analizi	70
Şekil 6.19. Inceptionv3 Karışıklık Matrisi.....	74
Şekil 6.20. Inceptionv3 Doğruluk Kayıp Grafikleri	75
Şekil 6.21. Inceptionv3 Grad-CAM Analizi	75
Şekil 6.22. Xception Karışıklık Matrisi	79
Şekil 6.23. Xception Doğruluk Kayıp Grafikleri.....	80
Şekil 6.24. Xception Grad-CAM Analizi	80
Şekil 6.25. MobileNetv2 Karışıklık Matrisi	84
Şekil 6.26. MobileNetv2 Doğruluk Kayıp Grafikleri	85
Şekil 6.27. MobileNetv2 Grad-CAM Analizi.....	85
Şekil 6.28. Meta Model Karışıklık Matrisi	89
Şekil 6.29. Meta Model Doğruluk Kayıp Grafikleri.....	90
Şekil 6.30. Meta Model Grad-CAM Analizi	90

SİMGELER VE KISALTMALAR LİSTESİ

AI	Artificial Intelligence
CNN	Convolutional Neural Network
Grad-CAM	Gradyan Ağırlıklı Sınıf Aktivasyon Haritalandırma
GAP	Küresel Ortalama Havuzlama
FC	Fully Connected
ROC	Alıcı İşletim Karakteristiği
AUC	Eğri Altındaki Alan
TPR	True Positive Rate
FPR	False Positive Rate
DSÖ	Dünya Sağlık Örgütü
PCR	Polimeraz Zincir Reaksiyonu
TP	True Positive
TN	True Negative
FP	Yanlış Pozitif
FN	Yanlış Negatif
CDC	ABD Hastalık Kontrol ve Korunma Merkezi

1. GİRİŞ

Maymun çiçeği virüsü ilk olarak 1958 yılında Kopenhag'da yer alan Statens Serum Enstitüsü'nde maymunlardan izole edilmiştir ve ismi de buradan gelmektedir [1]. Maymun çiçeği hastalığı ilk olarak Demokratik Kongo Cumhuriyeti'nde 1970 yılında keşfedilmiştir. İlgili tarihten itibaren vakaların çoğu Demokratik Kongo Cumhuriyeti'nden bildirilmeye devam etmektedir [2]. 1970'li ve 1980'li yıllarda bu zoonotik enfeksiyon üzerine yapılan kapsamlı çalışmalar, hastalığın büyük ölçüde sporadik (tekil, dağınık) olarak ortaya çıktığını ve kişiden kişiye bulaşmanın az görüldüğünü, genellikle iki nesilden öteye geçmediğini ortaya koymuştur. Ancak Ağustos 1996'da, insanlarda görülen maymun çiçeğiyle ilgili olağan dışı büyüklükte bir salgın bildirilmiştir ve vakalar 1997 yılı boyunca da devam etmiştir. Vaka sayılarında zirve artışlar Ağustos 1996, Mart 1997 ve Ağustos 1997 tarihlerinde kaydedilmiştir. 1997 yılında sahada yapılan ön araştırmalar, epidemiyolojik açıdan yeni bir modelin ortaya çıktığını düşündürmektedir ve ikincil vakaların çoğunluğunun kişiden kişiye bulaşma yoluyla meydana geldiği ve hastalığın ise klinik olarak daha hafif seyrettiği gözlemlenmiştir [3]. Tarihler 2003 yılını gösterdiğinde ABD'de ilk maymun çiçeği salgını gözlemlenmiştir. Salgında insandan insana bulaş gözlemlenmemiş olup, tüm vakaların sincap ailesine ait bir kemirgen olan çayır köpeklerine temas ile ortaya çıktığı gözlemlenmiştir [4].

Dünya Sağlık Örgütü (World Health Organization) 23 Temmuz 2022'de maymun çiçeği hastalığını, "Uluslararası Öneme Sahip Halk Sağlığı Acil Durumu (PHEIC)" olarak ilan etmiştir. Maymun çiçeği hastalığının dünya genelinde yaygınlaştığı ve yayılım gösterdiği Dünya Sağlık Örgütü'nün (DSÖ) raporuyla ortaya koyulmuştur. 23 Ağustos 2022 tarihiyle birlikte Avrupa Bölgesindeki 41 ülkede 21.098 vaka ve iki ölüm raporlanmıştır. Vakaların büyük çoğunluğu da erkeklerde görülmektedir [5]. Maymun çiçeği hastalığının yeniden ortaya çıkışı ve endemik olmayan ülkelerde artan vaka sayısı, küresel sağlık için yaklaşan bir tehdit haline gelmektedir. Bu nedenle, virüsün uygun metodolojilerle, en düşük yanlı sonuç oranıyla hızlı şekilde tespit edilmesi, krizin küresel boyutunun öngörülmesi ve koruyucu önlemlerin alınması açısından kritik bir rol oynamaktadır [6].

Hastalığın teşhis sürecinde Polimeraz Zincir Reaksiyonu (Polymerase Chain Reaction) testleri, hastalığın kontrolü ve yönetimi açısından altın standart olarak kabul edilmektedir [7]. Polimeraz Zincir Reaksiyonu (Polymerase Chain Reaction) testi altın standart olarak kabul edilmesine rağmen hastalığın en yaygın olduğu Afrika bölgesinde; sınırlı laboratuvar ekipmanı ve test kitleri, nitelikli yeterli sayıda personelin olmaması, maliyet gibi kısıtları da beraberinde getirmektedir [8]. Maymun çiçeği hastalığının Orta ve Batı Afrika bölgesinde endemik bir hastalık olmanın ötesine geçerek Avrupa ve Amerika’da hızlı şekilde eş zamanlı olarak yayılması ile hızlı teşhisin önemi ortaya çıkmıştır.

Yapay zekâ teknolojileri günümüzde sağlık alanında özellikle en son görülen COVID-19 salgınında hızlı teşhis sağlamak adına geliştirilmiş ve kullanılmıştır [9]. Maymun çiçeği hastalığının teşhisi için de literatürde en ileri düzey (state of the art) derin öğrenme modelleri, transfer öğrenme (transfer learning) yöntemiyle açık kaynak (open source) veri setleri üzerinde eğitilmiş ve modellerin karşılaştırmalı performans analizleri sunulmuştur [10], [11], [12].

Bu çalışmada, literatürden ve internet üzerinde açık kaynak veri tabanları üzerinden alınan maymun çiçeği cilt lezyon görüntüleri, diğer cilt lezyon görüntüleri ve normal cilt görüntüleri birleştirilerek tümleşik özel bir veri seti oluşturulmuştur. Literatür yayınları incelenerek en ileri düzey (state of the art) sekiz adet derin öğrenme modeli ve geliştirilen veri seti üzerinde eğitim ve test çalışmaları yapılmıştır. Modellerin performans metrik sonuçlarına göre daha yüksek başarı gösteren DenseNet201, DenseNet169 ve Xception modellerinin ara katmanlarından çıkartılan özellik vektörlerinin birleştirilmesiyle oluşturulan birleştirilmiş temsili özellik kümesi üzerinden meta model üretilmiş ve aynı veri seti üzerinde diğer modellere göre daha yüksek başarı sağlamıştır. Çalışmanın amacı, topluluk öğrenmesi (ensemble learning) yaklaşımının özellikle klinik uygulamalarda teşhis süreçlerine anlamlı katkı sunacağını göstermektir.

1.1. Çalışmanın Amacı

Bu çalışmanın amacı, geliştirilen veri seti ve topluluk öğrenmesi yaklaşımı ile maymun çiçeği klinik karar destek sistemi literatürünün de ilerisinde başarı sağlayan yeni bir model geliştirmek ve maymun çiçeği hastalığının cilt lezyon görüntüleri üzerinden etkili ve hızlı bir şekilde tespitini sağlamaktır. Maymun çiçeği hastalığının merkezi olan ve vaka sayısının da en yüksek olduğu Orta ve Batı Afrika bölgesinde, teşhis kitlerinin yeterli sayıda olmadığı, bulaş riskinin yüksek olduğu, halkın test kitlerine erişimin kolay olmadığı ve test sonuçlarının gün alıp, sonuçları yorumlayacak yeterli sayıda personelin de yer almadığı bilinmektedir.

Bu araştırmada ilk aşamada, büyük ve tümleşik bir veri havuzu oluşturulması hedeflenmiş ve bu amaç doğrultusunda literatürde yer alan yayınlar takip edilerek Kaggle ve DermNet platformlarından alınan cilt lezyon veri setleri ile hibrit bir veri tabanı oluşturulmuştur. Hibrit veri seti ile eğitilen modellerin daha yüksek sınıflandırma başarısı göstereceği hedeflenmektedir. Modellerin eğitimi ve testleri sonucunda en güçlü modellerin de özellikleri birleştirilerek çok daha yüksek sınıf tahminleme başarısı gösterecek yeni bir model geliştirilmesi amaçlanmıştır.

1.2. Çalışmanın Bilime Katkısı

Bu çalışma, maymun çiçeği cilt lezyon görüntülerini içeren literatürün ve açık kaynak diğer tüm veri setlerinin tamamını içermektedir. İlgili veritabanları birleştirildikten sonra Piksel Tabanlı Sağlama Toplamına Dayalı Yinelenme Önleme (Pixel Based Checksum Based Deduplication) yöntemi ile duplike olan cilt görüntüleri silinmiş ve bilim dünyasına kazandırılacak güncel veri tabanı oluşturulmuştur.

Literatürde yer alan en ileri seviye (state of the art) 8 adet derin öğrenme modeli kullanılmış ve literatür ile karşılaştırmalı olarak incelenmiştir. Veri setinde yer alan veri sayısının ve çeşitliliğinin, modelin performansına olan pozitif etkisi sayesinde literatürün de ilerisinde başarılı sınıflandırıcılar üretilmiştir. Özellik Seviyesinde Yığınlama Topluluk Öğrenmesi (Feature-level Stacking Ensemble Learning) yaklaşımıyla da güçlü modellerin de ilerisinde tahminleme performansı gösterecek yeni bir meta model oluşturulmuştur.

MobileNetV2 başta olmak üzere eğitilen sınıflandırıcılar mobil ve web uygulamalarına entegre edilebilir ve pratik hayatta da deneme amaçlı teşhis hedefli kullanılabilir.

1.3. Çalışmanın Kapsamı

Bu çalışma kapsamında veriler, açık kaynak veri kütüphaneleri üzerinden alınmıştır. Tüm veriler maymun çiçeği (monkeypox) ve maymun çiçeği olmayan (nonmonkeypox) olarak iki sınıfa ayrılmıştır. İlgili klasörlerde birbirinin aynısı olan görsellerinin kopyası, Piksel Tabanlı Sağlama Toplamına Dayalı Yinelenme Önleme (Pixel Based Checksum Based Deduplication) ve histogram tabanlı yöntemlerle karşılaştırılarak silinmiştir. Sonrasında görüntüler, model eğitim ve test faaliyetlerine uygun olacak şekilde 224x224 boyutuna ayarlanmış ve veri arttırımı (data augmentation) yöntemiyle veriler arttırılarak daha zengin veri tabanı elde edilmiştir. Model eğitimi, validasyonu ve testi için toplamda 8533 adet veri yer almaktadır. Literatür taraması faaliyeti sonucunda, Xception, InceptionV3, MobileNetV2, DenseNet121, DenseNet169, DenseNet201, VGG16, VGG19 modellerinin ağırlıkları kullanılarak ince ayarlama (fine tuning) yöntemiyle geliştirilen modeller üzerinden yeni veri seti ile eğitim, test ve validasyon çalışmaları gerçekleştirilmiştir. Performans ölçütleri olan doğruluk, hassasiyet, duyarlılık ve F-1 skoruna göre model performansları değerlendirilmiştir.

Yapılan değerlendirmeler neticesinde, özellik düzeyi yığınlama topluluk öğrenmesi (feature-level stacking ensemble learning) yaklaşımıyla DenseNet169, DenseNet201 ve Xception mimarilerin ilgili katmanlarından alınan özellikleri birleştirilerek yeni bir meta model geliştirilmiş olup, ayrı ayrı diğer derin öğrenme modellerine göre daha başarılı performans sonuçları sunmaktadır. Geliştirilen model, maymun çiçeği hastalığının cilt lezyon görüntüleri üzerinden tespit edilmesi için etkili bir çözüm olmasının yanında özellik düzeyi yığınlama topluluk öğrenmesi yaklaşımının klinik alanda lezyon, tümör ve diğer anomalilerin tespiti ve sınıflandırması için etkili bir teknik olduğu ortaya konulmaktadır.

2. MAYMUN ÇİÇEĞİ HASTALIĞI VE TARİHÇESİ

1958 yılında Preben von Magnus ve arkadaşları Singapur'dan gönderildikten sonra Kopenhag'a ulaşan iki ayrı *Cynomolgus* maymunu (*Macaca cynomolgus*) sevkiyatında çiçek benzeri bir hastalığın iki salgınını gözlemlemişlerdir. Yapılan deneysel çalışma sonucunda hayvanların yaklaşık %20 ila %30'u klinik hastalık belirtileri göstermiştir. Morfolojik olarak virüs, bilinen diğer çiçek virüslerine benzer şekilde dikdörtgen şekilli ve 200 x 250 nm boyutlarındadır. Antijenik açıdan ise vaccinia-variola alt grubuna yakın bir ilişkisi mevcuttur ancak; variola ve diğer bilinen çiçek virüslerinden farklılık gösterdiği için, bu virüse maymun çiçeği virüsü (monkeypox virus) adı verilmiş ve grubun özgün bir üyesi olarak tanınmıştır [13].

İnsan maymun çiçeği vakalarının çoğu, kendine özgü klinik bir görünüme sahiptir. Hastalık genellikle 2 günlük bir prodromal dönemle (başlangıç belirtileri dönemi) başlar ve ardından çiçek hastalığını andıran kompülsiyonlar gelişmektedir. Bu döküntüler, 2 ila 4 hafta süresince evreler hâlinde ilerler. Maymun çiçeği hastalığı insanda ilk kez 1970 yılında, Kongo Cumhuriyeti'nin Ekvator Bölgesi'ndeki Basankusu ilçesinde keşfedilmiştir. Bu bölgede çiçek hastalığının son vakasından iki yıl sonra meydana gelmiştir. Klinik olarak çiçek hastalığına benzeyen hastalık, epidemiyolojik açıdan önemli farklılıklar göstermektedir. Hastalığın 1970-1979 aralığında çocuklar, yetişkinlere kıyasla hastalıktan daha sık etkilenmiştir. Hastaların ortalama yaşı 8 (dağılım: 7 ay – 35 yaş) olup, medyan yaş 4 olarak belirlenmiştir. Toplam 47 vakanın 39'u (%83) 10 yaş altındadır; 25'i (%55) 5 yaş altı, 5'i (%11) ise 1 yaş altındadır. Hastaların 26'sı erkek, 21'i kadındır. Ancak, 15 yaş üstü hastalar arasında 7 kişiden 5'i kadındır [14]. Maymun çiçeği ilk insan vakalarından birine ait görsel Şekil 2.1'de gösterilmektedir.



Şekil 2.1. Maymun Çiçeği İlk İnsan Vakası

Maymun çiçeği hastalığı (monkeypox disease) uzun yıllar boyunca Orta ve Batı Afrika bölgesinde endemik bir hastalık olarak görüldükten sonra tarihler 8 Temmuz 2003 gösterdiğinde ilk insan vakaları ABD sınırları içinde bildirilmiştir. ABD Hastalık Kontrol ve Korunma Merkezleri'ne (CDC) göre 71 maymun çiçeği vakası bildirilmiştir. Bu vakalar şu eyaletlerden raporlanmıştır: Wisconsin (39), Indiana (16), Illinois (12), Missouri (2), Kansas (1) ve Ohio (1). İlgili vakaların 35'i ABD Hastalık Kontrol ve Korunma Merkezleri'ne (CDC) (%49) tarafından laboratuvar onaylı vakalardır; kalan 36 vaka (%51) ise, eyalet ve yerel sağlık birimleri tarafından araştırılmakta olan şüpheli veya olası vakalardır [15]. Şekil 2.2 'de seçilmiş özelliklere göre laboratuvar onaylı maymun çiçeği vakalarının sayısı ve yüzdesi gösterilmiştir.

Özellik	No.	(%)†
Eyalet		
Illinois	8	(23)
Indiana	7	(20)
Kansas	1	(3)
Wisconri	2	(6)
Yaş grubu, yıl	11	(31)
Cinsiyet	18	(51)
Olası maymun çiçeği maruziyet kaynakları		
Çayır köpeği	14	(40)
Çayır köpeği ve insan vakaları	14	(40)
Çayır köpeklerinin bulunduğu alanlar	6	(17)
Çayır köpeği ve insan vakalarının bulunduğu alanlar	1	(3)
Klinik özellikler		
Döküntü	34	(97)
Ateş	29	(85)
Solunum semptomları	27	(77)
Lenf bezi büyümesi	24	(69)

Şekil 2.2. ABD Hastalık Vaka Bildirimi

Tarihler 2022 yılı Mayıs ayı başını gösterdiğinde, maymun çiçeği vakaları, hastalığın endemik olmadığı birçok ülkeden bildirilmeye başlanmıştır. 9 Haziran 2022 itibarıyla, dünya genelinde 31 endemik olmayan ülkeden 1350'den fazla laboratuvar onaylı maymun çiçeği vakası bildirilmiştir. Bu vakaların yaklaşık %60'ı Portekiz, İspanya ve Birleşik Krallık olmak üzere üç ülkeden bildirilmiştir. Bildirilmiş vakaların çoğunun endemik bir ülkeye seyahatle ilişkili bir bağlantısı yoktur ve vakaların çoğu erkeklerle cinsel ilişkiye giren erkekler arasında görülmüştür. Bu durum, cinsel yolla bulaşma olasılığını gündeme getirmiştir [1].

Dünya Sağlık Örgütü (World Health Organization) 16 Kasım 2022 tarihinde yayınladığı Maymun Çiçeği Hastalığına İlişkin Çok Ülkeli Salgın Durumu (Multi-country outbreak of Monkeypox) adlı raporunda 1 Ocak 2022 ve 13 Kasım 2022 tarihleri arasında dünya genelinde 79.411 laboratuvar onaylı vaka ve 50 ölüm raporlanmıştır. Bölge bazlı rapor Şekil 2.3'de sunulmuştur.

DSÖ Bölgesi	Toplam Onaylanan Vakalar	Toplam Ölüm	Son Haftadaki Vakalar	7 Günlük Vaka Değişimi (%)
ABD	52 679	30	1007	- 20%
Avrupa	25 431	4	83	63%
Afrika	982	14	24	0%
Batı Pasifik	216	0	0	- 100%
Doğu Akdeniz	72	1	0	0%
Güney-Doğu Asya	31	1	0	- 100%
TOPLAM	79 411	50	1114	- 17%

Şekil 2.3. DSÖ Hastalık Genel Durumu

3. MAYMUN ÇİÇEĞİ HASTALIĞI TEŞHİS YÖNTEMLERİ

3.1. Dolaylı Teşhis Yöntemleri

Maymun çiçeği hastalığının dolaylı teşhisi, virüsü doğrudan tespit etmek yerine, insan vücudunda yarattığı birtakım etkiler veya değişimler üzerinden tanımlama yöntemidir. Hastalığın teşhisinde “Görüntü Tabanlı Teşhis Yöntemleri” ve “Virüs Kültürüne Dayalı Maymun Çiçeği Tanısı” kullanılmaktadır [16].

3.2. Doğrudan Teşhis Yöntemleri

Maymun çiçeği virüsünün doğrudan tespit edilmesi, virüsün kültür işlemi uygulanmadan doğrudan analizinin yapılmasıdır. Doğrudan tespit için Immünohistokimyasal Yöntemler (Monkeypox Immunodiagnosics), Tüm Virüs Partikülünün Tespiti (Whole-Particle Detection), Genom Dizileme Yoluyla Teşhis (Detection by Genome Sequencing), Polimeraz Zincir Reaksiyonu (Polymerase Chain Reaction) yöntemleri kullanılmaktadır [16].

3.3. Görüntü Tabanlı Teşhis Yönteminin Avantajı

Maymun çiçeği virüsünün tespit edilmesinde görüntü tabanlı yapay zekâ algoritmaları geliştirilmiştir. Vücudun farklı noktalarında oluşan tümör veya lezyon gibi rahatsızlıkları tespit etmek adına derin öğrenme ve makine öğrenmesi algoritmalarından faydalanılmaktadır. Özellikle derin öğrenme algoritmalarının tümör türlerini tespit etme konusunda başarısı ortadadır [17]. PCR ve türevlerinin maymun çiçeği hastalığının teşhisinde altın standart olduğu bilinmektedir [18]. PCR test kitlerinin hastalığın teşhisinde en güvenilir kaynak olduğu bilinmesine rağmen; Afrika bölgesinde tanı kitlerine erişimin zor olduğu, laboratuvar altyapısını uygun olmadığı ve sonuçları doğru yorumlayacak personelin de yeterli sayıda olmadığı bilinmektedir [19]. Yapılan literatür araştırması neticesinde laboratuvar teşhis ekipmanları yerine özellikle Afrika bölgesi veya temel teşhis cihazlarına erişimin zor olduğu bölgeler için mobil cihaz veya web sitesi üzerinden otomatik hızlı teşhis imkanı sunan klinik karar destek sistemi algoritmaları geliştirilmiştir [20], [21].

4. LİTERATÜR ARAŞTIRMASI

Hastalığın tedavi sürecinin doğru ve sağlıklı gerçekleştirilmesi için hastalığa doğru teşhis konulması gerekmektedir. Yapılan yanlış teşhis sonucu yanlış tedavi veya tedavi edilmeme durumlarında istenmeyen durumlar ile karşılaşmaktadır. Maymun Çiçeği (Monkeypox Disease) hastalığının teşhisini sağlamak amacıyla literatürde bulunan araştırma makaleleri (research articles) ve derleme makaleleri (review articles) ayrıntılı olarak incelenmiştir. Literatürde incelenen makalelerde, hastalığın teşhisi için Polimeraz Zincir Reaksiyonu (Polymerase Chain Reaction) testinin altın standart olarak kullanıldığını ancak; bulaş riskinin çok yüksek olduğu bölgelerde hızlı teşhisin öneminin ve ekipman, eleman yetersizliğinin söz konusu olduğu durumlarda yapay zekâ destekli klinik teşhis sistemlerinin kullanılabilirliği ifade edilmiştir. Araştırmacılar, hastalığın teşhisi için genellikle önceden eğitilmiş modelleri, benzer veri setleri ile eğitip, test etmişlerdir. Makalelerin sonuç raporlarında kullanılan modellerin tahminleme yetenekleri karşılaştırılmış ve nedenleri ile ortaya koyulmuştur.

Shams Nafisa Ali vd. yaptıkları çalışmada, ilk etapta halka açık vaka raporları, haber portalları, web siteleri üzerinden manuel araştırmalar ile Maymun Çiçeği Cilt Lezyon Veri Seti (Monkeypox Skin Lesion Dataset) geliştirmişlerdir. İnternet üzerinden yapılan veri seti toplama çalışması sonucunda toplam 228 adet cilt görseli elde edilmiş ve bu görsellerin 102 tanesi Maymun Çiçeği (Monkeypox), 126 tanesi Su Çiçeği (Chickenpox) ve Kızamık (Measles) hastalıklarına aittir. Model tahminleme performansını arttırmak amacıyla veri artırma (data augmentation) işlemi uygulanmış ve 1428 Maymun Çiçeği (Monkeypox) ve 1764 diğer hastalıkları içeren görsellerin olduğu toplamda 3192 adet veri elde edilmiştir. Çalışmanın deney aşamasında VGG16, ResNet50, InceptionV3 ve hibrit model kullanılmış ve ResNet50 (%82,96±4,57) doğruluğa (accuracy) ulaşarak en başarılı ikili sınıflandırmayı sağlamıştır. VGG16 (%81,48±6,87), hibrit model (%79,26±1,05), InceptionV3 (%74,07±3,78) doğruluk (accuracy) değerlerine sahiptir. Web tabanlı maymun çiçeği hastalığı teşhisi uygulaması geliştirilmiş ve en iyi performans gösteren model kullanılarak hastalık teşhisi sağlanmıştır [11].

Md. Manjurul Ahsan vd. gerçekleştirdikleri çalışmada, internet üzerinden edindikleri maymun çiçeği, suçiçeği, kızamık ve normal cilt görüntülerine; onay formuyla bireylerden aldıkları normal cilt görüntülerini de ekleyerek “Monkeypox2022” adında yeni bir veri seti geliştirmişlerdir. Modelin başarılı sınıflandırma performansı için veri artırma (data augmentation) tekniği uygulanmıştır. İşlem sonrasında 4 sınıftan toplamda 1915 adet veri yer almaktadır. Çalışmada ince ayarlama (fine tuning) kullanılarak VVG16 modeli sınıflandırma için kullanılmıştır. Md Manjurul Ahsan vd. tarafından gerçekleştirilen çalışma, çalışma-1 ve çalışma-2 olarak ayrılmış ve çalışma-1’de sınırlı sayıda veri maymun çiçeği ve suçiçeği sınıflarını sınıflandırma için kullanılmış olup, çalışma-2 de ise veri artırma (data augmentation) işlemi sonrasında elde edilen maymun çiçeği ve diğer veriler ayrılarak sınıflandırma için hazırlanmıştır. Ayrılan çalışmalar için en uygun hiperparametre değerleri ızgara araması (grid search) tekniği ile belirlenmiştir. Çalışma-1’de model, test seti üzerinde (%83±0.085) doğruluğa, çalışma-2’de ise (%78±0.022) doğruluğa ulaşmıştır. Modelin tahminlerini de açıklamak amacıyla LIME algoritması kullanılmıştır. İlgili çalışma, hastalığın DSÖ tarafından acil durum ilan edildiği dönemde yeni veri seti sunduğu ve transfer tabanlı yaklaşım geliştirdiği için maymun çiçeği hastalığının yapay zekâ araçları ile tespit edilmesi konusunda danışılacak bir kaynak konumuna gelmiştir [26].

Diponkor Bala vd. araştırma çalışmasında, internet üzerindeki kaynaklardan, dergilerden vs. elde ettikleri vücudun farklı yerlerinden alınan dört farklı görüntü sınıfından 770 adet (maymun çiçeği, suçiçeği, kızamık, normal) oluşan Maymun Çiçeği Hastalığı Cilt Görüntüleri (Monkeypox Skin Images Dataset) veri setini oluşturmuşlardır. Diponkor Bala vd. oluşturulan veri seti literatürdeki pek çok yayının deneysel çalışmasında da kullanılmıştır. Google platformu üzerinden alınan veri seti üzerinde görüntü ön işleme operasyonları yapılarak görüntüler model eğitimi için hazır hale getirilmişlerdir. RGB formatında, 224 x 224 boyutunda, normalizasyon işlemi tamamlanmış olan görseller, veri artırımı öncesinde eğitim, validasyon ve test veri havuzları olarak ayrılmışlardır ve işlem sonrasında toplam 8689 adet veri yer almaktadır. Yazarların yaptıkları ilk çalışmada, farklı derin öğrenme modellerini özellik çıkartmak amaçlı ve final tahminini yapmak için de makine öğrenmesi sınıflandırıcılarını kullanmışlardır. İkinci etapta, çalışmada önerdikleri ve modifiye ederek geliştirdikleri DenseNet-201 mimarisinin orijinal ve arttırılmış veri üzerindeki diğer modellere göre üstün başarısını (test doğrulu orijinal veri seti (%91.91), arttırılmış veri seti (%98.91)) tablo olarak ortaya koymuşlardır. Çalışmada genel olarak güçlü bir veri seti, geliştirilmiş bir model ve farklı hiperparametre değerleri üzerinden, 4 farklı sınıf

için en güçlü performansı sağlayan model ve parametre değerleri seçilerek oldukça başarılı performans metrik çıktılarına ulaşılmıştır [23].

Veysel Harun Şahin vd. yaptıkları çalışmada, açık kaynak veri seti üzerinden ResNet18, GoogleNet, EfficientNetb0, NasnetMobile, ShuffleNet, MobileNetv2 modelleri ile gerçekleştirdikleri eğitim ve test çalışmaları sonucunda 60 döngü (epoch) sonucunda MobileNetv2 sınıflandırıcısının %91.11 ikili sınıflandırma doğruluğuna sahip olduğu deneysel olarak ifade edilmiştir. Tensorflow yazılım çatısı (framework) kullanılarak geliştirilen ve eğitilen mobil cihazlar için daha uyumlu ve düşük boyutlu MobileNetv2 modeli, Tensorflow Lite modeline dönüştürülerek Android uygulamasına yerleştirilmiştir. Teşhis kitlerinin olmadığı veya eksik olduğu, tecrübeli personelin eksikliğinin yaşandığı ve özellikle Afrika gibi yüksek hastalık bulaş riskinin olduğu bölgelerde hızlı teşhis sağlamak adına pratik anlamda kullanılacak rehber bir çalışmadır [20].

Chiranjibi Sitaula vd. araştırmalarında transfer öğrenme yaklaşımıyla 13 adet güncel derin öğrenme modelini, çoklu sınıflandırma (multiple classification) yapmak için çalışmalarında kullanmışlardır. Deneysel sonuçlara göre test veri seti üzerinde ince ayarlama (fine tuning) işlemleri yapılmış Xception modeli %85.01 ve DenseNet169 modeli ise %84.07 doğruluğa ulaşarak diğer derin öğrenme modellerine göre daha yüksek sınıflandırma başarısı göstermişlerdir. İki modelin güçlü yönlerinin kullanarak daha doğru tahmin yapmak amacıyla oylama topluluk öğrenmesi (voting ensemble learning) yaklaşımı kullanılmıştır ve çalışmada modellerin tahminleri ve girdi görüntüsü üzerinden nihai karar çoğunluk oylaması ile verilmiştir. Topluluk öğrenmesi yaklaşımı sonucunda model %87.13 doğruluğa ulaşarak tekli modellerden daha yüksek performans sunmuştur [66].

Murat Altun vd. çalışmasında parametre ve katman mimarisinde değişiklikler yaparak geliştirdikleri yeni MobileNetV3 modelinin, EfficientNetV2s, VGG19, ResNet50, DenseNet modellerine göre daha yüksek sınıflandırma başarısı gösterdiğini ortaya koymuştur. Araştırmacıların çalışmada kullandıkları veri seti, internet siteleri üzerinden otomatik olarak veri çekme yöntemiyle gerçekleştirilmiş olup açık kaynak veri seti kullanılmamıştır. Literatürde yer alan çalışmaların büyük çoğunluğunda olduğu gibi bu çalışmada da modelin aşırı öğrenmesini (overfitting) veya az öğrenmesini (underfitting) engellemek amacıyla veri artırımı (data augmentation) yöntemi uygulanmıştır. İlgili mimarinin, Shams Nafisa Ali vd., Md Manjurul Ahsan vd. çalışmalarında ortaya koydukları

modellere göre daha yüksek performans göstermesinin nedenini, doğru hiperparametre optimizasyonu olduğunu çalışmada ifade edilmiştir. Araştırmacılar çalışmada veri setinin önemine vurgu yapmış ve veri setlerinin herhangi bir sağlık kuruluşu tarafından paylaşılmadığı ve tıp uzmanları tarafından herhangi bir veri setinin de valide edilmediği belirtilmiştir. YOLO ve Detectron2 modellerinin başarılı sınıflandırıcılar olabileceği öngörüsünde bulunulmuştur [68].

Yavuz Selim Taşpınar vd. yaptıkları çalışmada, VGG16, VGG19 ve ince ayarlanmış (fine tuning) VGG16, VGG19 modellerini kullanarak performans karşılaştırması yapmıştır. İnce ayarlama işlemi sonrasında VGG16 modelinin doğruluğunun %95.61 seviyesinden %96.87 seviyesine; VGG19 modelinin doğruluğunun ise %96.08 seviyesinden %97.81 seviyesine yükseldiği gözlemlenmiştir. Makalede aktivasyon fonksiyonu olarak Leaky RELU kullanılmasının modelin ikili sınıflandırma başarısına önemli bir katkı sunduğu vurgulanmıştır. Araştırmacılar yaptıkları çalışma sonucunda mobil uygulama geliştirmişler ve ince ayarlanmış (fine tuning) VGG19 modelini kullanarak kamera veya galeri üzerinden yüklenen cilt görüntülerini pozitif veya negatif olarak sınıflandırmışlardır. Yapılan çalışma, doğru hiperparametre optimizasyonunun model performansına olan büyük etkisini ortaya koymuştur, modelin pratik bir uygulamada da kullanılması gerçek dünyada kullanımı için de örnek teşkil etmiştir [62].

Alexander H. Thieme vd. çalışmalarında Stanford University Medical Center hastanesinden erkek hastalardan elde ettikleri veriler ve internet üzerinden ulaştıkları veriler ile literatürdeki en büyük cilt lezyon veri setlerinden bir tanesini elde etmişlerdir. Veri seti, toplamda 139,138 adet cilt lezyon görüntüsünü içermekte olup, 676 adet veri maymun çiçeği hastalığına aittir ve hastanenin veritabanı üzerinden de veri alınmıştır. ResNet18, ResNet34, ResNet50, Resnet152, DenseNet169 ve VGG19 modelleri ile eğitim yapılmış ve ResNet34 mimarisi eğitim ve test işlemleri için seçilmiştir. Sınıflar arasındaki dengesizliği önlemek için ağırlıklı kategorik çapraz entropi kaybı fonksiyonu (weighted categorical cross-entropy loss function) kullanılmıştır. Araştırmacılar web tabanlı anket üzerinden tanı uygulaması geliştirmişlerdir. Bu çalışma; yeni ve gelişmiş veri seti içermesi, FastAI v2 gibi farklı bir yazılım geliştirme çatısı (framework) kullanılması ve web tabanlı anket içeren sınıflandırma uygulaması içermesi yönlerinden literatürden ayrılarak, ileri çalışmalara da rehberlik etmiştir [63].

Aqsa Akram vd. çalışmada, Diponkor Bala vd. internet üzerinden veri toplayarak geliştirdikleri veri setini kullanmışlardır. Veri artırımı işlemi sonrasında, Hafif Gradyan Artırma Algoritması (LightGBM), Rastgele Orman (Random Forest), Lojistik Regresyon (Logistic Regression), Ekstra Ağaçlar (Extra Trees), Inception v3, Xception, ResNet50 algoritmalarını kullanarak eğitim ve test gerçekleştirilmiştir. Inception v3, Xception, ResNet50 modelleri üzerinden oylama topluluk öğrenmesi (voting ensemble learning) yöntemiyle ve ek gizli katmanlar (hidden layers) ekleyerek SkinMarkNet olarak tanıtılan yeni bir model geliştirilmiş ve 4 farklı sınıf grubunun sınıflandırılmasında, %90 doğruluğa (accuracy), %89 duyarlılık (recall), %90 kesinlik (precision), %89 F-1 skoru performans çıktıklarına test seti üzerinden ulaşılmıştır [64].

Sarmad Maqsood vd. çalışmada, literatürdeki 4 farklı sınıf verisi içeren orijinal olarak toplam 770 adet, artırma işleme sonrası toplamda 8689 görsel barındıran veri setini ilgili kullanmışlardır [23]. Modelin daha yüksek performans gösterebilmesi için araştırmacılar kontrast iyileştirmesi yapmışlardır ve birleştirme tabanlı kontrast iyileştirme algoritması (fusion-based contrast enhancement algorithm) çalışmada kullanılmıştır. Bu algoritma ile düşük yoğunluk seviyesine sahip piksellerin yoğunluk seviyeleri artırılarak pikseller arasında yoğunluk seviyesi farkı azaltılmıştır. Veri seti geliştirme işlemi sonrasında 6 adet önceden eğitilmiş ViT, Swin Transformer, ResNet-50, ResNet-101, EfficientNetV2, ConvNeXt-V2 derin öğrenme modelleri deneyde eğitim amaçlı kullanılmıştır. Sonrasında farklı modellerin sınıflandırma güçlerini ortak kullanarak Evrişimli Seyrek Görüntü Ayırıştırma (Convolutional Sparse Image Decomposition) yöntemi ile özellik birleştirme (feature fusion) işlemi yapılmış ve önerilen modelin (MOX-NET) en sonunda çok sınıflı M-SVM makine öğrenmesi sınıflandırıcısı ile final tahmini gerçekleştirilmiştir [65].

Sohaib Asif vd. yaptıkları çalışmada yenilikçi meta-sezgisel (meta-heuristic) tabanlı topluluk öğrenmesi yaklaşımıyla oldukça yüksek performans ortaya koyan yeni bir model geliştirmişlerdir. Yenilikçi model ile araştırmacılar, farklı modellerin (DenseNet201, MobileNet ve DenseNet169) katman yapılarını geliştirip, ağırlık ortalama topluluk öğrenmesi ve PSO algoritması ile modeller için en uygun ağırlıkların seçimi üzerine odaklanmaktadır. Deneysel çalışma sonucunda hibrit model, diğer modellere göre test verisi üzerinde ikili sınıflandırma kapsamında %97.78, dört sınıf için %92.86 doğruluğa ulaşarak en yüksek performansı göstermiştir [69].

Md Manjurul Ahsan vd. yaptıkları çalışmada geliştirilmiş dört farklı veri seti üzerinden VVG-16, ResNet-50, ResNet-101, görsel dönüştürücüler (vision transformers) ile eğitim, validasyon ve test yapılmıştır. Çalışmada dağıtık öğrenme (federated learning) yöntemiyle farklı kaynaklardaki verilerden merkeziyetsiz model eğitimi yapılmasına imkan sağlanarak veri güvenliği sağlanmakta olup, model parametreleri merkezi bir sunucuda güncellenerek modellerin daha iyi genelleme yapması sağlanmıştır. Modellerin daha yüksek başarı göstermesi için de kafes arama (grid search) ile farklı hiperparametre optimizasyonu uygulanmıştır. Yerel Yorumlanabilir Modelden Bağımsız Açıklamalar (Local Interpretable Model-Agnostic Explanations) algoritması ile modellerin sınıf tahmininde bulunduğu bölgeler vurgulanmıştır. Dağıtık öğrenme (federated learning) yaklaşımıyla veri güvenliği sağlanarak, modellerin daha iyi genelleme yapmaları sağlanmıştır. Sağlık verilerinin önemi ortadadır ve veri güvenliği için dağıtık öğrenme yaklaşımı önemli bir yöntemdir. Klinik karar destek sistemlerinin geliştirilmesinde ilerde de sıklıkla başvurulacak bir yöntem olacaktır [67].

5. MATERYAL VE YÖNTEM

5.1. Veri Setinin Hazırlanması

5.1.1. Veri setinin açık kaynak veritabanları üzerinden elde edilmesi

Bu çalışmada, literatürdeki araştırmalar incelenerek ve internet üzerinden klinik veri tabanları taranarak hibrit bir veri seti oluşturulmuştur. Maymun çiçeği hastalığı üzerine internette tamamen doğrulanmış, büyük bir veri seti yer almamaktadır. Yapay zekâ çalışmalarında veri biliminin de önemi oldukça büyüktür. Büyük ve çeşitli veri setleri, model performansını doğrudan olumlu etkilemektedir [22]. Literatürdeki araştırmaların da ilerisine geçebilmek ve önerilecek modelin en iyi seviyede olmasını sağlamak için büyük bir veri seti oluşturmak çalışmanın birincil adımı olmuştur.

Diponkor Bala vd. yazdıkları araştırma makalesinde geliştirdikleri ve kullandıkları veri seti toplam 4 sınıflı veri içermektedir. Suçiçeği hastalığı ile ilgili veri setinde toplam png formatında 224x224 boyutlarında 107 adet cilt lezyon görüntüsü, kızamık hastalığı için png formatında 224x224 boyutlarında 91 adet cilt lezyon görüntüsü, maymun çiçeği hastalığı üzerine png 224x224 boyutlarında 279 adet cilt lezyon görüntüsü ve normal png 224x224 boyutlarında 293 adet cilt görüntüsü veri havuzu içerisinde yer almaktadır [23].

DermNet tarafından yayınlanan Mpox Images (Maymun Çiçeği Verileri) veri setinde, farklı boyutlarda png formatında toplam 28 adet maymun çiçeği hastalığına sahip vücutun farklı yerlerinden alınmış cilt lezyon görüntüsü yer almaktadır [24].

Kaggle platformu üzerinden farklı cilt lezyon görüntülerinin, maymun çiçeği cilt görüntülerinin de yer aldığı “Data_Monkeypox” adından açık kaynak veri seti indirilmiştir. Veritabanı toplamda 4 adet sınıftan oluşmaktadır. Hibrit veri havuzuna dahil edilecek maymun çiçeği cilt görüntülerinden farklı boyutlarda png formatında toplam 42 adet, normal cilt görüntülerinden farklı boyutlarda png formatında toplam 20 adet, altıncı hastalık (roseola) için png formatında ve farklı boyutlarda 15 adet, kızıl hastalığı (scarlet) için de png formatında ve farklı boyutlarda 16 adet cilt lezyon görüntüsü yer almaktadır [25].

Hibrit veri setine dahil edilen dördüncü veritabanı Ahsan vd. çalışmasında geliştirilmiştir ve veritabanı, “Monkeypox2022” adıyla açık kaynak olarak Github üzerinden erişilmektedir. Hibrit veri setine “Monkeypox2022” veri setinden üç farklı sınıfta görseller dahil edilmiştir. Veri setinde toplam 27 adet png formatında farklı boyutlarda kızamık cilt lezyon görüntüleri, 45 adet png formatında farklı boyutlarda maymun çiçeği cilt lezyon görüntüleri ve 33 adet png formatında farklı boyutlarda normal cilt görüntüleri yer almaktadır [26].

Shams Ali vd. yaptıkları çalışmada kullandıkları veri seti baz alınarak ve iki adet sınıfın verileri dahil edilerek ilgili veri seti, hibrit veri setinin içerisine dahil edilmiştir. Hibrit veritabanına dahil edilen veri setinin içerisinde 224x224 boyutlarında png formatında toplamda 70 adet maymun çiçeği cilt lezyon görüntüleri, 31 adet 224x224 boyutlarında png formatında diğer normal ve hastalıklı cilt lezyon görüntülerinin yer aldığı görüntü sınıfı klasörü yer almaktadır [11].

Veri toplama çalışmasında son etapta, internet üzerinden Google arama motoru ile yapılan araştırma sonucunda, monkeypox anahtar kelimesi yazılarak yüksek çözünürlüklü görüntüler hibrit veri setine dahil edilmiştir. Hibrit veri seti maymun çiçeği olan ve diğer olarak iki farklı klasöre ayrılmıştır. Maymun çiçeği cilt lezyon görüntülerinin yer aldığı klasörde 741 adet ve maymun çiçeği, maymun çiçeği olmayan cilt görüntülerinin olduğu klasörde ise 1124 adet görsel yer almaktadır.

5.1.2. Duplike olan verilerin silinmesi

Veri toplama işlemi sonrasında tüm veriler iki farklı sınıfa ayrılarak dosyalarda toplanmıştır. Klasörler içerisinde birbirinin aynısı görseller yer alabilir ve birbirini tekrar eden görsellerin kopyasının silinmesi gerekmektedir. Piksel Tabanlı Sağlama Toplamına Dayalı Yinelenme Önleme (Pixel Based Checksum Based Deduplication) yöntemi ile Maymun Çiçeği Olan ve diğer klasörlerinde birebir aynı olan görseller tespit edilerek birden fazla kopyası silinmiştir. Piksel Tabanlı Sağlama Toplamına Dayalı Yinelenme Önleme yönteminde öncelikle görüntülerin piksel matrisi alınmaktadır. Görüntü içerisinde yer alan piksellerin üzerinden RGB değerleri, hex değerlerine dönüştürülmektedir. Çıkan değerler MD5 algoritmasına girdi olarak verilir ve görüntü içeriğini temsil eden 128-bit özet bir görüntü oluşmaktadır [74]. Dosyanın adı, tag değeri veya metadata değerleri aynı da olsa

piksel içeriği farklı olacağından birbirinin aynısı olan görseller ilgili yöntem ile tespit edilecektir. Piksel Tabanlı Sağlama Toplamına Dayalı Yinelenme algoritması öncesinde, maymun çiçeği virüsü ile enfekte olan bireylerin farklı vücut bölgelerinden alınan cilt lezyon görüntüleri toplam 741 adet ve diğer cilt görüntüleri de toplam 1124 adettir. Veri artırımı işlemi öncesinde 510 adet maymun çiçeği cilt lezyon görüntüsü, 749 adet maymun çiçeği olmayan cilt görüntüsü Piksel Tabanlı Sağlama Toplamına Dayalı Yinelenme algoritması sonrasında elde edilmiştir.

Sahte veya duplike olan görsellerin tespit edilmesinde renk içeriklerine odaklanarak HSV uzayında histogram tabanlı karşılaştırma yapılmaktadır [73]. Görseller HSV renk uzayına dönüştürülerek cv2.compareHist() fonksiyonu ile histogramlar arası benzerlik değerlendirilmiştir. Histogramlar arası karşılaştırma yapmak amacıyla cv2.HISTCMP_CORREL korelasyon yöntemi kullanılmıştır ve tamamen aynı histograma sahip olan görseller silinmiştir. Maymun çiçeği sınıfından toplam 509 görsel, maymun çiçeği olmayan sınıftan ise toplam 746 adet görsel veri setinde yer almaktadır. Piksel Tabanlı Sağlama Toplamına Dayalı Yinelenme Önleme yöntemiyle karşılaştırıldığında genel fark oranı yaklaşık %0.32'dir ve ilgili fark oldukça düşüktür. İki yöntem ile duplike olan görsellerin silinmesi işlemi değerlendirilmiştir.

5.1.3. Görüntülerin png dönüşümü ve boyutlarının ayarlanması

Veri toplama çalışmasında son etapta, internet üzerinden Google arama motoru ile yapılan araştırma sonucunda, monkeypox anahtar kelimesi yazılarak yüksek çözünürlüklü görüntüler hibrit veri setine dahil edilmiştir. Hibrit veri seti maymun çiçeği olan ve diğer olarak iki farklı klasöre ayrılmıştır. Maymun çiçeği cilt lezyon görüntülerinin yer aldığı klasörde 741 adet ve maymun çiçeği olmayan cilt görüntülerinin olduğu klasörde ise 1124 adet görsel yer almaktadır. Pozitif ve negatif klasörlerin içerisindeki tüm jpg, jpeg ve jfif uzantılı olan görseller Operating System (İşletim Sistemi) ve Python Görüntü Kütüphanesi (Python Imaging Library) aracılığıyla png formatına dönüştürülmüş ve ayrı klasörlerde tutulmuştur.

Pozitif ve negatif sınıf klasörlerindeki görseller aynı görüntü formatına getirildikten sonra görüntülerin boyutları, eğitilecekleri derin öğrenme tabanlı modellerin veri girdi boyutlarına uygun hale getirilmiştir. Açık kaynak veri tabanları üzerinden, internetteki diğer

kaynaklar üzerinden alınan veriler, 224 x 224 piksel boyutuna Açık Kaynak Görüntü İşleme Kütüphanesi (Open Source Computer Vision) ve İşletim Sistemi (Operating System) kütüphaneleri ve ilgili fonksiyonları kullanılarak ayarlanmıştır. Ölçeklendirilmiş görüntü boyutu, daha büyük boyuttaki görsellere göre daha az GPU belleği tüketir ve eğitim süresini de optimize eder. Ayarlanan görüntü boyutu, yüksek doğruluk ve kabul edilebilir hesaplama yükü için isabetli bir seçim olmaktadır.

5.1.4. Veri artırma işlemi

Veri artırma (data augmentation) işlemi, yapay zekâ dünyasında yetersiz düzeyde veri olduğunda veya model performansı geliştirilmek istendiğinde en sık başvurulan yöntemlerin başında gelmektedir. Veri artırma (data augmentation) işlemi veri uzayında (data space) veya özellik uzayında (feature space) gerçekleştirilmektedir ve yapılan deneyde, veri uzayında veri artırma işleminin özellik uzayında veri artırma işlemine göre daha etkili olduğu gözlemlenmiştir [27]. Bu çalışmada, literatür dikkate alınarak veri uzayında veri artırma işlemi gerçekleştirilmiştir. Veri artırma teknikleri üzerinde yapılan araştırma sonucunda yoğun veri artırma (heavy data augmentation) teknikleri çalışmada kullanılmıştır [28]. Tablo 5.1. 'de çalışmada yer alan veri artırma işleminde kullanılan parametre değerleri gösterilmiştir. Şekil 5.1. 'de ise ayrı klasörlerde yer alan maymun çiçeği hastalığı ve maymun çiçeği hastalığı olmayan cilt görselleri gösterilmektedir.

Tablo 5.1. Veri Artırma Değerler

Veri Çoğaltma Türü	Parametre Adı	Değer Açıklaması
Rastgele Döndürme	rotation_range	0 ile 40 derece arasında rastgele döndürme
Yatay Kaydırma	width_shift_range	Görüntünün genişliğinin %20'si kadar kaydırma
Dikey Kaydırma	height_shift_range	Görüntünün yüksekliğinin %20'si kadar kaydırma
Kesme (Shearing)	shear_range	Görüntüye 0.2 oranında kesme (açılı kaydırma)

Yakınlaştırma	zoom_range	Görüntüyü %20 oranında yakınlaştırma/uzaklaştırma
Yatay Çevirme	horizontal_flip	True → Rastgele yatay çevirme uygulanır.
Doldurma Modu	fill_mode	'nearest' → Boş kalan pikseller en yakın piksel



Şekil 5.1. Maymun Çiçeği ve Normal İnsan Görüntüleri

5.2. Derin Öğrenme

Yapay zekânın önemli iki alanı olan makine öğrenmesi ve derin öğrenme analitik sistemlerin temelini oluşturmaktadır. Derin öğrenme, makine öğrenmesinin alt dalı ve ilerici teknoloji olarak karşımıza çıkmaktadır [29]. Makine öğrenimi kavramının alt dalı olan derin öğrenmenin, ortaya koyduğu yenilikçi yanları mevcuttur. Derin öğrenme teknolojisi özünde yapay sinir ağlarından ortaya çıkmıştır. Derin öğrenme tabanlı mimarilerin doğrudan veri üzerinden öğrenebilmesi özellikle karmaşık problemlerin yüksek hassasiyet ve doğrulukta çözülmesinde etkin rol oynamıştır. Makine öğrenmesi algoritmalarının aksine veri sayısının artırılmasıyla model performansının da arttığı gözlemlenmiştir; ancak büyük veriler ile yapılan eğitim süreleri uzun olmakla birlikte kaynak tüketimi de makine öğrenmesi algoritmalarına göre daha yüksektir [30].

Derin öğrenme mimarisinin temelinde sinir sisteminden ilham alınarak geliştirildiği bilinmektedir. İnsan beyni ve sinir sistemi elemanlarının yaptıkları gibi derin öğrenmede bilgiyi katmanlar halinde işleyerek genel bir yargıya varmasıdır. İnsan vücudunda kortikal katmanlar ile derin öğrenme mimarilerindeki katman yapıları işlev ve amaç bağlamında benzerlik göstermektedir. Derin öğrenme mimarilerinde bilginin üst üste katmanlar tarafından işlenip özellikleri detaylı olarak çıkarılması gibi insan beyni ve sinir sistemi öğeleri de benzer işlemi gerçekleştirir [31].

Derin öğrenme mimarileri, görsel, metin, ses vb. veriler üzerinden kullanıcı tarafından belirlenen özelliklerin tanımlanması yerine makine öğrenmesi mimarisinde farklı olarak doğrudan veriler üzerinden öğrenir. Veri sayısının, katman mimarisinin ve derinliğinin artırılması öğrenme sürecini olumlu etkileyebilir. Yapay zekâ dünyasında istenmeyen aşırı öğrenme (overfitting) ve yetersiz öğrenme (underfitting) sonuçları ile karşılaşmamak adına veri miktarının ve model mimarisinin doğru ayarlanması gerekmektedir. Eğitim verisinin az ve modelin çok katmanlı, karışık bir model olduğu durumlarda aşırı öğrenme (overfitting), oldukça basit modellerin ise yetersiz öğrenme (underfitting) neden olduğu bilinmektedir [32].

Derin öğrenme teknolojilerinde dikkat edilmesi gereken belirli hususlar yer almaktadır. İlgili hususlara riayet edilmediğinde model performansı ve genelleme yeteneği istenen seviyelerde olmamaktadır. Veri setinde yer alan veri adedinin model karmaşıklığına ve hedeflenen model başarısına göre yeterli seviyede olması ve uzmanlar tarafından onaylı olması gerekmektedir. Eksik ve hatalı veriler modelin yanlış tahmin yapmasını sağlayabilir. Veri seti içerisindeki verilerin gürültüden arındırılmış olması da modelin veriler üzerindeki özellikleri doğru öğrenmesini sağlayacaktır. Yüksek gürültülü verilerde model gürültü özelliklerini de öğrendiği için eğitim sonrası oluşturulan model, gerçek dünyadaki temiz görüntüdeki nesne veya nesnelere algılayamayabilir. İlgili çalışmada Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi (ANFIS) ile veri temizleme ve hata düzeltme işlemi gerçekleştirilmiş medyan filtreler ile de karşılaştırılmıştır. Veri temizleme araçlarının model performansında son derece önemli olduğu karşılaştırmalı olarak vurgulanmıştır [33]. Veri sayısının yetersiz olması veya temiz olması haricinde sınıflar arası verinin de dengeli olması önem arz etmektedir. Literatürde veri dengesizliğini ortadan kaldırmak adına Sentetik

Azınlık Sınıfı Aşırı Örneklemme Tekniği (SMOTE), Alt Örneklemme (Undersampling), Sınıf Ağırlıkları (Class Weights) yöntemleri yer almaktadır [34].

Aşırı karmaşık modeller (overparameterization) yüksek hesap maliyeti oluşturduğundan eğitimi zorlaştırabilir ve modeli aşırı öğrenmeye yatkın hale getirebilir [35]. Modellerin uzun eğitim süreleri ve zaman, donanım maliyetleri yapay zekâ geliştiriciler açısından önemli kısıtlar olmaktadır. Literatürde yer alan çalışmada model, birbirinden bağımsız ve paralel birden fazla alt modele bölünerek, alt görevler üzerinden eğitilmiştir. Model performansı başarısını korurken eğitim süresi azalmaktadır [36]. Şekil 5.2.'de derin öğrenme model performansını etkileyen temel hususlar sıralanmıştır.

NO	MODEL PERFORMANSINI ETKİLEYEN HUSUSLAR
1	Veri Sayısı & Çeşitliliği
2	Uzman Ekip Tarafından Verilerin Onaylanması
3	Veri Temizleme
4	Veri Dengesi
5	Model Mimarisi
6	Donanım Maliyetleri

Şekil 5.2. Model Performansını Etkileyen Hususlar

Yapay zekâ alanının bir alt dalı olan Derin Öğrenme (Deep Learning) yöntemlerini denetimli (supervised) ve denetimsiz (unsupervised) öğrenme olarak iki ana kategoriye ayrılmaktadır.

5.2.1. Denetimli öğrenme

Denetimli Öğrenme (Supervised Learning), makine öğrenmesinde kullanılan bilinen tekniklerden birisidir. Şekil 5.3.'de gösterildiği üzere, modelin eğitilmesi için her bir veriye karşılık gelen etiket değerleri de yer almaktadır [41]. Model, etiketli veriler aracılığıyla girdiler ile çıktılar arasındaki ilişkiyi öğrenir ve sonrasında etiketsiz veriler için doğru tahminlerde bulunabilir. Denetimli öğrenme, nesne tespiti, doğal dil işleme, tıbbi analiz, endüstriyel kalite süreçlerinde ve pek çok uygulamada kullanılan bir yapay zekâ tekniğidir. Denetimli öğrenme pozitif ve negatif sınıfları birbirinden ayırt etmek, sayısal tahminler yapmak amacıyla kullanılabilir. Denetimli öğrenme içerisinde Lineer Regresyon (Linear Regression), Logistic Regression (Lojistik Regresyon), Karar Ağaçları (Decision Tree), Rastgele Orman (Random Forest), Destek Vektör Makineleri (Support Vector Machine), K-En Yakın Komşu (KNN), Yapay Sinir Ağları (ANN), Yinelemeli Sinir Ağları (RNN) metotları yer almaktadır. Denetimli öğrenme ile modelin başarısı rahatlıkla ölçülebilir, genellikle doğru modelleme ve veri ile yüksek doğru sağlayabilir, eğitim ve değerlendirme süreçleri daha sistematiktir [40].



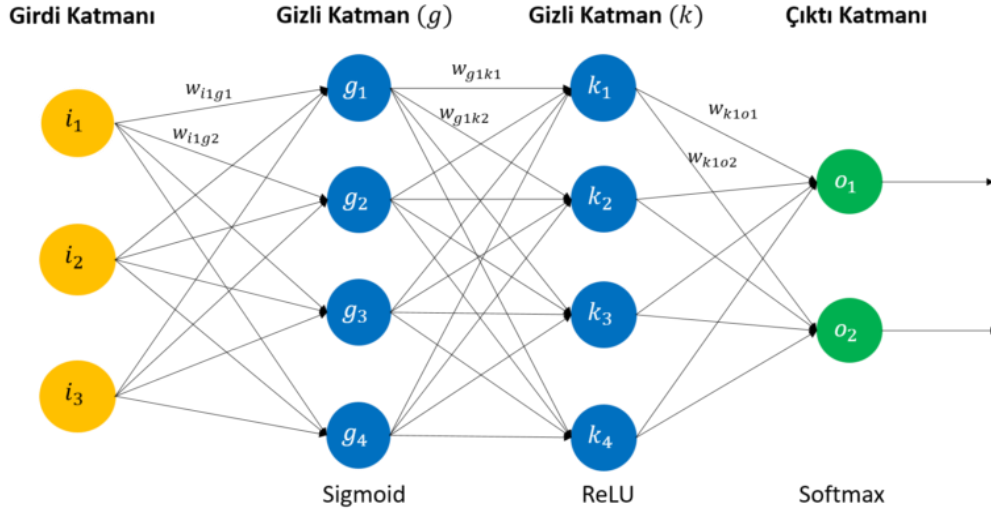
Şekil 5.3. Denetimli Öğrenme Örneği

5.2.2. Denetimsiz öğrenme

Denetimsiz öğrenme (unsupervised learning), makine öğrenmesi algoritmalarında bir algoritmanın etiketsiz verilerle çalışarak, veriler arasındaki örüntüleri veya ilişkileri öğrenmeye çalışan bir yöntemdir. Etiketsiz veriler üzerinde sinir ağları aracılığıyla anlamlı öznitelikleri öğrenmek amacıyla geliştirilmiştir. İlgili çalışmada üç başlık altında bilgi koruyan yöntemler, yoğunluk tahmin yöntemleri ve öznitelik çıkarma yöntemleri olarak ayrılmıştır. Oja kuralı, PCA benzeri otomatik kodlayıcılar (autoencoders), boltzmann makineleri, SOM, çok katmanlı yapılar denetimsiz öğrenme yöntemleri arasındadır [70].

5.3. Yapay Sinir Ağları

Yapay Sinir Ağları (Artificial Neural Networks – ANN), insan anatomisindeki sinir hücrelerinden ilham alınarak geliştirilmiş yapay zekâ sistemleridir. Yapay sinir ağları örüntü algılama, sınıflandırma, tahminleme işlevlerini yerine getirmektedirler. Yapay sinir ağları temel olarak girdi katmanından, gizli katmanlardan ve çıktı katmanından oluşmaktadır. Şekil 5.4. 'de genel hatlarıyla yapay sinir ağının diyagram halinde modellenmesi gösterilmektedir [37]. Bir yapay sinir ağının derinliği de gizli katman adeti ile ilgili bir konudur. Algoritmanın temel süreci, veri değerlerinin belirli katsayılar ile çarpılması, toplanması ve ilgili işlem adımlarıyla aktivasyon fonksiyonu aracılığıyla çıktıya dönüştürmesidir. Girdi verisinin etiketi ile çıktı verisinin etiketinin tüm veriler için yüksek oranda örtüşmesi amaçlanmaktadır. Eğitilen modeller, gerçek bir dünyada hiç karşılaşmadıkları bir problemi çözmek için tasarlanırlar. Yapay Sinir Ağı mimarileri, çok katmanlı yapılardan oluşmaktadır ve katman mimarisi sayesinde karmaşık özellikleri öğrenebilir ve özellikle dış dünyadaki karmaşık, soyut problemlerin çözülmesine önemli bir katkı sağlamaktadır. Yapay sinir ağları ileri beslemeli hesaplama (forward propagation) ve geri yayılım (backpropagation) algoritmaları ile veriler üzerinden öğrenir. Modelin aktivasyon fonksiyonu sonrası çıktısı ile gerçek değer karşılaştırılarak kayıp fonksiyonu (loss function) hesaplanır ve gradyan inişi (gradient descent) optimizasyonu ile sinir ağındaki ağırlıklar güncellenir. Modelin bir iterasyonu ileri beslemeli hesaplama ve geri yayılım sürecinin tamamlanmasıyla gerçekleşir ve model daha iyi genelleme yapmak adına da her iterasyonda kendisini günceller [38].




Şekil 5.4. Yapay Sinir Ağları

5.3.1. Evrişimsel sinir ağları

Evrişimsel sinir ağlarının keşfi aslında tarihteki makine öğrenmesi çalışmalarının bir çıktısı olarak günümüz teknolojilerinde birçok problemin çözülmesi amacıyla kullanılmaktadır. Sinir ağı teknolojisi insan vücudundan ve sinir sisteminden etkilenecek başlamıştır. 1890'lı yıllarda insan beyninin yapısı ve çalışma prensibi bilimsel olarak ortaya koyulmuştur. Literatürde ilk yapay sinir ağı modeli 1943 yılında Warren S. McCulloch ve Walter Pitts tarafından geliştirilmiştir [42]. Tarihler 1957 senesini gösterdiğinde Frank Rosenblatt tarafından tek katmanlı bir yapay sinir ağının temeli olan algılayıcı (perceptron) keşfi ile çalışmalar sinir ağları literatüründe hız kazanmıştır [43]. Kunihiko Fukushima tarafından 1980 yılında, beyin görsel korteksini taklit etmeye çalışan ve görüntü tanıma görevlerinde kullanılmak üzere geliştirilmiş bir sinir ağı modeli olan Neocognitron adında tanıma amaçlı geliştirilmiş çok katmanlı hiyerarşik bir sinir ağı tanıtılmıştır. İlgili yapı bir giriş katmanından ve bağlanmış çok sayıda modülden oluşmaktadır. Her modül iki katmandan meydana gelmektedir. S hücreleri (Simple cells) basit görsel özellikleri algılar ve C hücreleri (C cells) de bu özellikleri birleştirerek daha karmaşık desenleri algılamaktadır. Neocognitron modeli, evrişimsel sinir ağı mimarilerinin öncüsü olarak kabul edilmektedir ve görüntüleri konumdan bağımsız olarak tanıyabilen ilk yapay sinir ağı örneklerinden birisidir [44].

Yann LeCun vd. tarafından yapılan çalışmada 1998 yılında LeNet-5 modeli tanıtılmıştır. LeNet-5 modeli, el yazısı rakamların ve basılı karakterlerin otomatik tanınması problemleri için geliştirilmiş bir evrimsel sinir ağı mimarisidir. Günümüz yapay zekâ dünyasında eğitim ve diğer çalışmalarda kullanılan MNIST veri seti de bu çalışma ile tanıtılmıştır. Model, bankacılık sektöründe çeklerin üzerindeki el yazısı rakamların okunmasında başarıyla uygulanmıştır [45]. Günümüz dünyasında derin öğrenme alanında en önemli başarılarından birisi de 2012 senesinde Image-Net yarışmasında derin öğrenme modelinin, makine öğrenme modellerine göre bariz üstünlüğü olmuştur. Klasik makine öğrenmesi algoritmalarında çok daha üst seviyede başarı gösteren evrimsel sinir ağı olan Alex-Net yarışmayı ilk sırada tamamlamıştır. Alex-Net çok katmanlı bir evrimsel sinir ağıdır. Toplam 5 adet evrimsel katman ve 3 adet tam bağlantılı katmandan oluşmaktadır. Aktivasyon fonksiyonu olarak Sigmoid ve Tanh yerine RELU kullanılarak eğitim süresini kısaltarak modelin derin ağ özelliği sayesinde detaylı özellik çıkartarak daha iyi öğrenmesini sağlamıştır. Makine öğrenmesi veya az katmanlı derin öğrenme modelleri aşırı öğrenme veya yetersiz seviyede öğrenme gibi istenmeyen neticeler ortaya koymalarına karşın ilgili çalışma ile dropout tekniği kullanılarak istenmeyen model başarısızlığı problemlerinin önüne geçilmiştir. Modelin gerçek dünyadaki oldukça karmaşık problemleri çözmesi için de veri seti üzerinde veri arttırma işlemi yapılmıştır. Model eğitiminde CPU yerine GPU kullanılması ile zaman maliyeti ciddi seviyede azalmıştır. Literatüre kazandırılan yenilikçi adımlar ile imaj tabanlı derin öğrenme teknolojilerinde inovasyon çalışmaları hız kazanmıştır [46].

Evrimsel Sinir Ağları (Convolutional Neural Networks), özellikle görüntü verileri üzerinde etkili bir şekilde kullanılan çok katmanlı yapay sinir ağlarıdır. Evrimsel Sinir Ağları, klasik yapay sinir ağlarından farklı olarak, görüntülerin yapısal özelliklerini doğrudan giriş verisinden çıkarma yeteneğine sahiptir. Ağ üzerinde özellikle tam bağlantılı katmanlar öncesinde yapılan filtreleme işlemi ile görüntülerin özellikleri yakalanıp, görüntü sınıflandırma, tespit, segmentasyon vb. işlemler için kullanılacak önemli özellik bilgileri öğrenilmektedir. Evrimsel Sinir Ağları, evrim katmanı (convolutional layer), pooling layer (havuzlama katmanı), aktivasyon fonksiyonu (activation layer), düzleştirme katmanı (flatten layer), tam bağlantılı katman (fully connected layer) öğelerinden oluşmaktadır. Şekil 5.5. 'de gösterildiği üzere ilgili görüntü üzerinde filtreleme operasyonları ve örnekleme ile anlamlı detaylar çıkartılarak modelin görüntüler üzerinden doğrudan öğrenmesi sağlanmaktadır [45].



Şekil 5.5. Evrişimsel Sinir Ağları

5.3.1.1. Evrişim katmanı

Evrişim katmanı, evrişimsel sinir ağlarının önemli bir parçasıdır. Evrişim katmanı, görüntüler gibi çok boyutlu verilerdeki yerel özellikleri otomatik olarak çıkarmaya yarar. Geleneksel yapay sinir ağlarından farklı olarak, evrişim katmanları verideki mekânsal ilişkileri koruyarak işlem yapar ve bu yönüyle özellikle görüntü işleme, nesne tanıma ve tıbbi görüntü analizi gibi alanlarda yaygın şekilde kullanılmaktadır. Evrişim işlemi sırasında girdi verileri üzerinde hareket eden küçük boyutlu filtreler kullanılır. İlgili filtreler, giriş verisi ile etkileşime girerek özellik haritaları üretir. Hiperparametre olarak kullanılabilen her filtre farklı bir deseni algılamak üzere eğitilir. Matematiksel olarak evrişim işlemi aşağıda olduğu gibi tanımlanmaktadır [47].

$$S(i,j)=(I*K)(i,j)=m\sum_n\sum_l I(i+m,j+n)\cdot K(m,n) \quad (5.1)$$

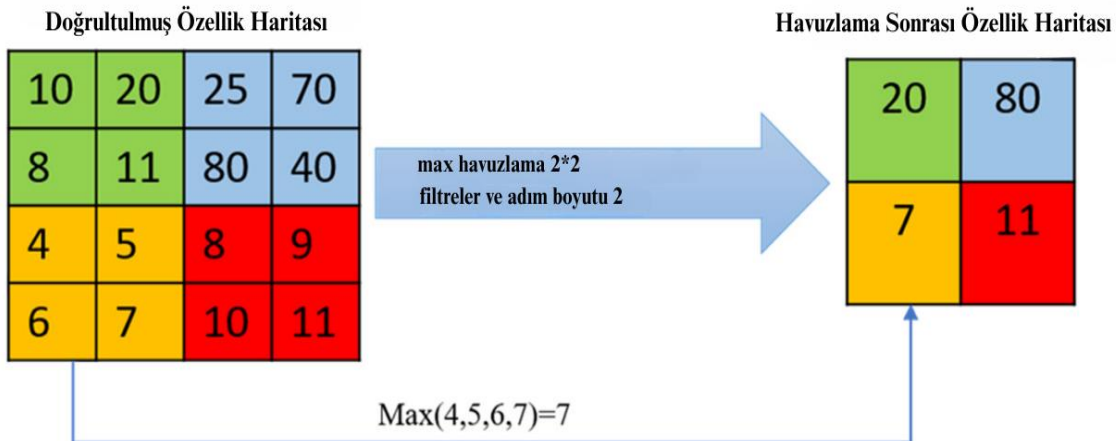
Konvolüsyon işlemi, giriş tensörüne (veriye) farklı çekirdekler (kernels) uygulanarak gerçekleştirilir. Her bir çekirdek farklı özellikleri çıkarır, bu nedenle çekirdekler farklı özellik çıkarıcılar gibi düşünülebilir. Bu işlem tekrarlandıkça, girişten farklı özellik haritaları (feature maps) elde edilir. Konvolüsyon işlemi tanımlayan iki temel hiperparametre yer almaktadır. Konvolüsyon işleminde çekirdek boyutu ve çekirdek sayısı model performansını belirleyen önemli ölçütlerdir. Görüntüler üzerindeki detayları korumak ve özellik

haritalarının boyutlarının giriş görüntülerinden daha küçük olmasına engellemek adına dolgulama (padding) operasyonu uygulanmaktadır.

5.3.1.2. Havuzlama katmanı

Havuzlama katmanı, evrişimli sinir ağlarında (Convolutional Neural Networks - CNN) yaygın olarak kullanılan, boyut indirgeme ve öznitelik çıkarımı işlemlerini gerçekleştiren bir katmandır. Havuzlama türleri genel olarak maksimum ve ortalama havuzlama olmak üzere ikiye ayrılmaktadır. Havuzlama katmanının temel amacı, anlamsal olarak benzer öznitelikleri bir araya getirerek daha soyut bir temsil oluşturmaktır. Çünkü bir motifi oluşturan özniteliklerin göreceli konumları biraz değişse bile, bu motifi doğru şekilde algılamak için bu konumsal bilgiyi daha kaba bir şekilde (coarse-grained) ele almak yeterlidir. Tipik bir havuzlama birimi, öznitelik haritası üzerinde yerel bir yamanın maksimum değerini alır. Komşu havuzlama birimleri, bu yamaları birden fazla piksel kaydırarak örnekledikleri için, boyutsal azaltma sağlarlar ve böylece küçük konumsal kaymalara veya bozulmalara karşı değişmezlik elde edilir [38].

Maksimum havuzlama, girişten belirli boyuttaki bölgelerde (örneğin 2×2) en yüksek değeri seçerek çalışır. Örneğin, Şekil 5.6.'da 4×4 'lük bir girişten, 2 adım aralığı (stride) ile 2×2 filtre uygulanarak çıktı oluşturulur. Bu işlemde her bölgedeki en büyük değer (örneğin 20) çıkartılır ve çıktı haritası bu maksimum değerlerden oluşturulur. Ancak, bu yöntem yalnızca en büyük değeri dikkate alır ve diğer bilgileri göz ardı eder. Bu nedenle, eğer birçok öge yüksek değere sahipse, önemli öznitelikler kaybolabilir ve bu da model performansını olumsuz etkileyebilir [49].

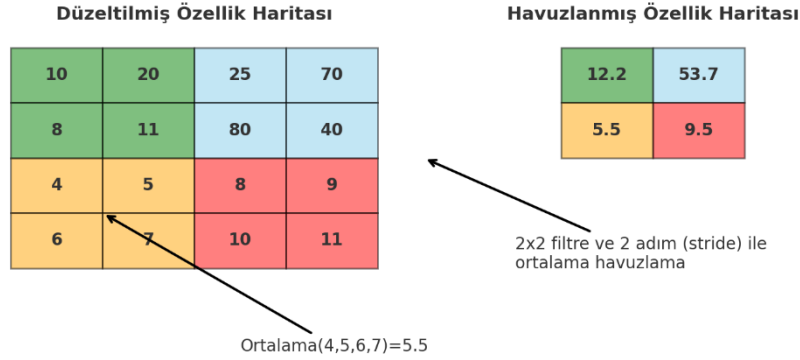


Şekil 5.6. Maksimum Havuzlama İşlemi

Ortalama havuzlama, giriş verisini dikdörtgen bölgelere ayırarak her bir bölgedeki değerlerin ortalamasını alır ve böylece boyut indirgeme işlemini gerçekleştirir. Bu yöntem ilk olarak evrişim tabanlı derin sinir ağlarında kullanılmıştır. İşlemden önce, her dikdörtgen alan (örneğin 2×2) için ortalama değer hesaplanır ve bu değerler çıktı haritasını oluşturur. Ortalama havuzlama aşağıda matematiksel olarak tanımlanır [49].

$$f_{ave}(X) = \frac{1}{N} \sum_{i=1}^N x_i \quad (5.2)$$

Aşağıda yer alan Şekil 5.7.'de ortalama havuzlama (average pooling) işlemi görüntü üzerinde gösterilmektedir [49].



Şekil 5.7. Ortalama Havuzlama İşlemi

5.3.2. Aktivasyon fonksiyonları

Aktivasyon fonksiyonları yapay zekâ dünyasında model eğitimi sırasında kullanılan önemli bir parametredir. Doğru problemler için doğru aktivasyon fonksiyonlarının seçilmesi modelin genelleme başarısını doğrudan etkilemektedir. İkili sınıflandırma yapılması beklenen problemler için “sigmoid” veya basit sinir ağları için “tanh” aktivasyon fonksiyonları kullanılırken, daha gelişmiş ve karmaşık problemleri çözmek için “ReLU” veya türevleri kullanılabilir. Literatürde yapılan güncel çalışmalar incelendiğinde de farklı problem türlerine göre araştırmacıların en doğru aktivasyon fonksiyonunu seçmeye çalıştıkları görülmektedir. İlgili çalışmada son 30 yıl içerisinde 400’ün üzerinde aktivasyon fonksiyonu sistematik olarak incelenmiş ve bu aktivasyon fonksiyonları sabit ve uyarlanabilir olmak üzere iki ana kategoriye ayrılmıştır. Sabit aktivasyon fonksiyonları arasında sigmoid, tanh, ReLU, Leaky ReLU, ELU, GELU, Mish yer almaktadır [50].

5.3.2.1.Sigmoid fonksiyonu

Sigmoid, doğrusal olmayan bir aktivasyon fonksiyonudur. Genellikle klasik yapay sinir ağlarında ve binary sınıflandırmada kullanılır. Fonksiyonun çıkış aralığı 0-1 arasındadır. Fonksiyon sürekli ve türevlenebilir. Olasılık temelli çıktılar için uygundur ve basit bir yapıya sahiptir. Büyük negatif veya pozitif değerler için türev beklenenden çok küçülebilir ve öğrenme sürecini de etkileyebilir. Matematiksel formülü aşağıda gösterilmiştir [50].

$$f(x) = 1 / (1 + e^{(-x)}) \quad (5,3)$$

5.3.2.2.Tanh Fonksiyonu

Tanh, sigmoid'in sıfır merkezli versiyonudur. Derin ağlarda sigmoid'e kıyasla daha avantajlıdır. Çıkış aralığı: (-1, 1) arasındadır. Sıfır merkezlidir ve sürekli, türevlenebilir. Öğrenmeyi hızlandırabilir çünkü ortalamaya daha yakın değerler üretir. Simetrik çıktı üretir; ancak kaybolan gradyan (vanishing gradient) problemi oluşturabilir. Matematiksel formülü aşağıda gösterilmiştir [50].

$$f(x) = (e^x - e^{-x}) / (e^x + e^{-x}) = \tanh(x) \quad (5,4)$$

5.3.2.3. ReLU (Doğrultulmuş Lineer Birim) fonksiyonu

ReLU, en yaygın aktivasyon fonksiyonlarından biridir. Sade ve verimlidir. Çıkış aralığı $[0, \infty)$ arasındadır ve özellikle karmaşık ve parametre adeti yüksek olan problemler için hesaplama verimliliği sağlar. Gradyan problemlerine karşı dayanıklıdır. Hızlı öğrenme sağlar ve derin ağlarda başarılıdır. Matematiksel formülü aşağıda gösterilmiştir [50].

$$f(x) = \max(0, x) \quad (5,5)$$

5.3.2.4. Leaky ReLU (Sızdıran ReLU) fonksiyonu

Ölü ReLU problemine çözüm olarak getirilmiştir ve negatif değerlerde küçük bir eğim bırakmaktadır. ReLU aktivasyon fonksiyonu gibi pozitif girişlerde aynıdır; ancak

negatiflerde de küçük gradyan sağlamaktadır. Ölü ReLU problemine karşı daha dayanıklıdır; ancak küçük negatif eğimin değerinin doğru konfigüre edilmesi gerekmektedir. Matematiksel formülü aşağıda gösterilmiştir [50].

$$f(x) = \begin{cases} x & \text{if } x > 0 \\ \alpha x & \text{if } x \leq 0 \end{cases} \quad (\alpha \approx 0.01) \quad (5,6)$$

5.3.3. Optimizasyon (Optimizer)

Yapay zekâda optimizasyon işlemi, bir modelin belirli bir amaca ulaşması için parametrelerin sistematik olarak düzenlenmesi sürecidir. Optimizasyon türleri klasik gradyan tabanlı yöntemler (classical gradient-based methods), momentum tabanlı yöntemler (momentum-based methods), uyarlanabilir öğrenme oranlı yöntemler (adaptive learning rate methods), sezgisel/meta sezgisel yöntemler (heuristic/meta-heuristic methods) olarak sıralanabilir. İlgili çalışmada, derin öğrenmede kullanılan çeşitli optimizasyon algoritmalarını hem denetimli hem de denetimsiz görevlerde karşılaştırmalı olarak incelenmiştir. Çalışmada farklı veri setleri üzerinden de karşılaştırmalı analiz yapılmıştır. Yapılan analiz sonucunda adaptif öğrenme algoritmalarının önemi vurgulanmıştır [51]. Literatürde ilgili konu üzerinde araştırma yapıldığında SGD ve Adam optimizerlerinin daha yoğun kullanıldığı görülmektedir. SGD algoritması ve özellikle matematiksel altyapısına dair yazarlar tarafından rastgele örneklemeyle dayalı iteratif bir yaklaşım olduğu ortaya çıkarılmıştır. İlgili yaklaşımla her adımda bir örneklem ile güncelleme yapılmaktadır ve öğrenme oranı (learning rate) zamanla azalmaktadır. Yöntem gürültülü verilere karşı dayanıklıdır [52]. SGD optimizasyon yönteminin pratik anlamda tanıtıldığı makalede çok katmanlı yapay sinir ağlarının eğitilmesi için kullanılan backpropagation (geri yayılım) algoritması tanıtılmıştır. Bu yöntem ile hata sinyalleri ağ boyunca geriye doğru yayılmaktadır ve ağırlıklar, her bir eğitim örneğine göre güncellenmektedir. İlgili süreç SGD optimizasyonu ile gerçekleştirilmektedir ve matematiksel formülü aşağıda gösterilmektedir [53].

$$\theta_{t+1} = \theta_t - \eta \nabla \theta L(\theta_t) \quad (5,7)$$

Adam, adaptif öğrenme oranları ve moment tahminleri sayesinde derin öğrenmede hem hız hem de performans açısından güçlü bir optimizasyon yöntemidir. Özellikle SGD ve diğer


adaptif algoritmalarla kıyasla daha kararlı ve verimli sonuçlar vermektedir. Bu yüzden günümüzde pek çok uygulamada varsayılan optimizasyon algoritması olarak kullanılmaktadır. Adam optimizasyonu, hem momentum bazlı gradyanların birinci moment ve ikinci momentini hesaplamaktadır. Öğrenme hızını tüm parametreler için adaptif olarak ayarlamaktadır, hızlı ve kararlı yakınsama sağlar. Standart olarak kullanılan SGD göre daha az parametre ayarı gerektirmektedir. Aşağıda Adam optimizasyonunun matematiksel formülü yer almaktadır [54].

$$\theta_{t+1} = \theta_t - \eta \frac{\hat{m}_t}{\sqrt{\hat{v}_t + \epsilon}} \quad (5,8)$$

5.3.4. Tam bağlantılı katman

Tam bağlantılı katman (fully connected layer), derin öğrenme dünyasında sıkça kullanılan temel kavramlardan birisidir. Tam bağlantılı katmanda, her bir nöron bir önceki katmandaki tüm nöronlarla bağlantılıdır. Tam bağlantılı katman, derin öğrenme model mimarisinde ilgili verinin özellikleri çıkarıldıktan sonra uygulanır. Katman sonunda yer alan fonksiyon ile sınıflandırma, regresyon vb. problemlerin çözümü amaçlanır. Bağlantı sayısı çok olduğu için parametre sayısı fazladır, bu da aşırı öğrenme (overfitting) riskini artırabilir. Aşırı öğrenme riskini minimize etmek amacıyla katman mimarisi, nöron sayısı ve diğer hiperparametre teknikleri doğru bir şekilde belirlenmelidir. Özellikle görüntü işleme gibi karmaşık problemler için öncesinde evrişim katmanı, havuzlama katmanı kullanılır ve çıktı öncesinde karar aşamasında tam bağlantılı katman (fully connected layer) kullanılmaktadır. Gizli katmanlar, giriş sinyallerini işleyip öğrenmeye yardımcı olan nöronlardan oluşmaktadır ve tüm nöronlar birbirine bağlıdır. Tam bağlantılı katman sonrasında model çıktı katmanı ve aktivasyon fonksiyonu vasıtasıyla nihai tahminini yapar. İlgili çıktı sonucu, girişteki ışık sinyallerine göre yapılmaktadır. İlgili çalışmada, farklı dalga boylarında ölçülen

ışık sinyalleriyle, bitki ve su örneklerindeki klorofil miktarını yapay zekâ ile tahmin edilmektedir [55].



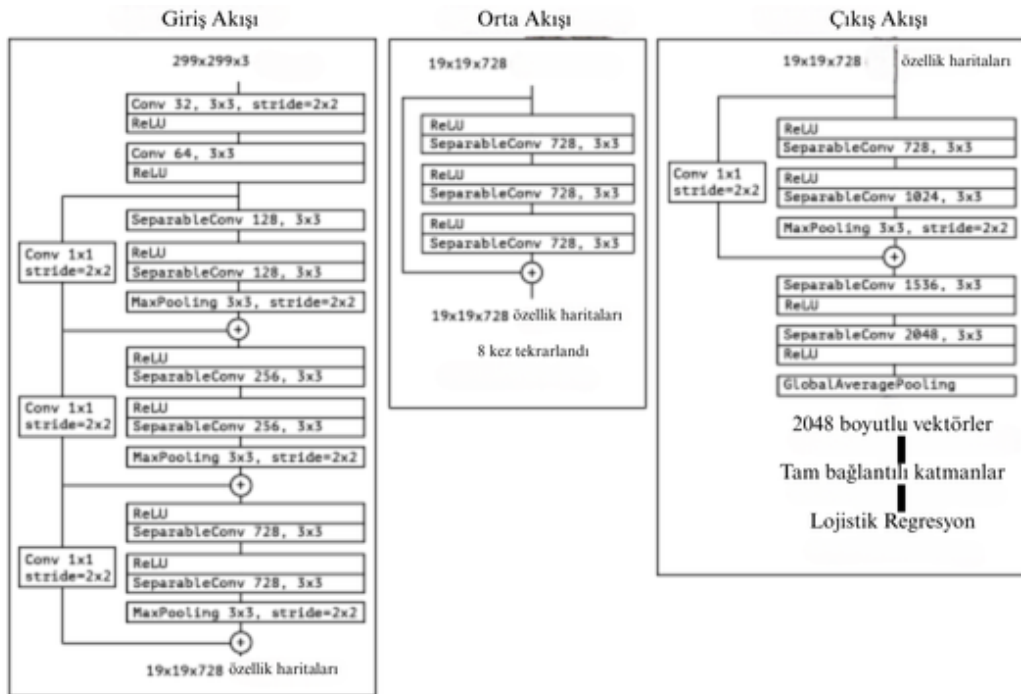
Şekil 5.8. Tam Bağlantılı Katman Modeli

5.4. Çalışmada Yer Alan Modeller

5.4.1. Xception

Xception, Inception mimarisinin ilerici bir sürümü olarak tasarlanmış derin bir yapay sinir ağı modelidir. Mimarinin özgünlüğü, klasik evrişim işleminin yerini alarak her bir kanal için ayrı derinlikli (depthwise) evrişim işleminin yapılması ve ardından 1×1 'lik (pointwise) evrişimle kanallararası etkileşimi yeniden oluşturmasıdır. Bu işlem ile aynı sayıda parametreyle daha verimli ve hızlı öğrenme sağlanmaktadır. Modelin, Inception mimarisinin güncel ve ilerici sürümleri ile Imagenet ve büyük veri setleri üzerinde performans karşılaştırması yapılmış ve daha yüksek başarı göstermiştir. Oldukça büyük JTF veri seti üzerinde VGG-16 ve ResNet-152'ye göre daha başarılı performans göstermiştir. gibi bilinen Medikal görüntü sınıflandırma gibi alanlarda hızlı uyum ve yüksek başarı sağladığı literatürde yer almaktadır. Konvolüsyonel katmanlar ile derinliğine ayrılabilir konvolüsyonlar, mimari karmaşıklık açısından bir spektrumun iki uç noktasını oluştururken; Inception modülleri bu spektrumun orta noktasında yer almaktadır. İlgili çalışmada yazar, görüntü işleme mimarilerinde Inception modüllerinin yerine derinliğe ayrılabilir konvolüsyonların kullanılmasını ortaya koyduğu yenilikçi mimari ile göstermiştir. Xception mimarisinin parametre sayısı Inception mimarisi ile benzerdir ama daha kararlı bir performans ortaya koymaktadır. Derinliğine Ayrışılabilir Konvolüsyon (Depthwise Separable Convolution) ilgili çalışmada yenilikçi model mimarisinin temel yapı taşı olmuştur.

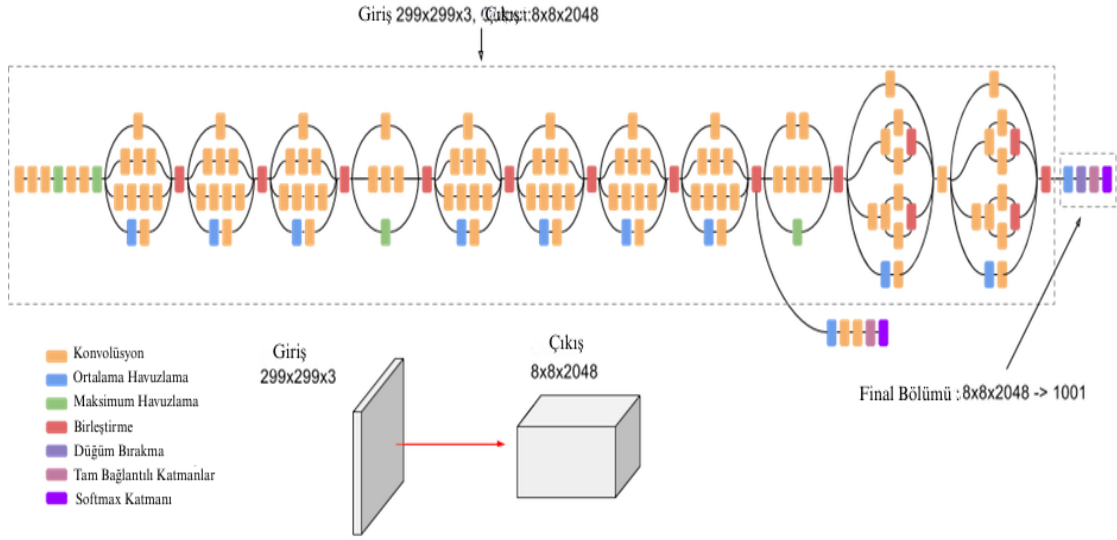
Konvolüsyonlar ile derinliğine ayrılabilir konvolüsyonların farklılıkları bulunmaktadır. Standart evrişim işleminde bir evrişim çekirdeği, tüm giriş kanallarını aynı anda kullanarak özellik haritalarını oluşturur. İlgili süreç ile her filtre, giriş verisinin tüm kanallarıyla birlikte işlem yapar. Derinliğine ayrılabilir konvolüsyon işlemi derinlemesine konvolüsyon ve noktasal konvolüsyon olmak üzere iki aşamalıdır. Derinliğine konvolüsyon işleminde her kanal için ayrı uzamsal filtre uygulanır ve renk ve özellik kanalları birbirinden ayrı olarak işlenmektedir. İşlem sonrasında noktasal konvolüsyon işlemi uygulanır ve ilgili kanallar 1x1 konvolüsyonlarla birleştirilir ve bu sayede kanallar arası etkileşim artar. İlgili işlem adımları sonrasında daha az hesaplama, parametre sayısı ile yüksek genelleme yeteneğine sahip derin sinir ağı mimarisi oluşturulmaktadır. Xception mimarisi üç temel bloktan oluşmaktadır. Xception mimarisinde veriler önce giriş akışından (entry flow) geçmektedir, ardından sekiz kez tekrar edilen orta akış (middle flow) katmanlarından geçerek son olarak çıkış akışına (exit flow) ulaşır. Ayrıca, kullanılan tüm ayrılabilir evrişim katmanlarında derinlik çarpanı (depth multiplier) değeri makalede 1 olarak belirlenmiştir. Şekil 5.9’da ilgili mimari, katmanlar arasındaki düzeni ve işleyişi özetlerken; hesaplama verimliliğini artırmak amacıyla seçilen ayrılabilir evrişimlerin, kanal başına bir filtre ile çalıştığını da vurgular [56].



Şekil 5.9. Xception Mimarisi

5.4.2. Inception V3

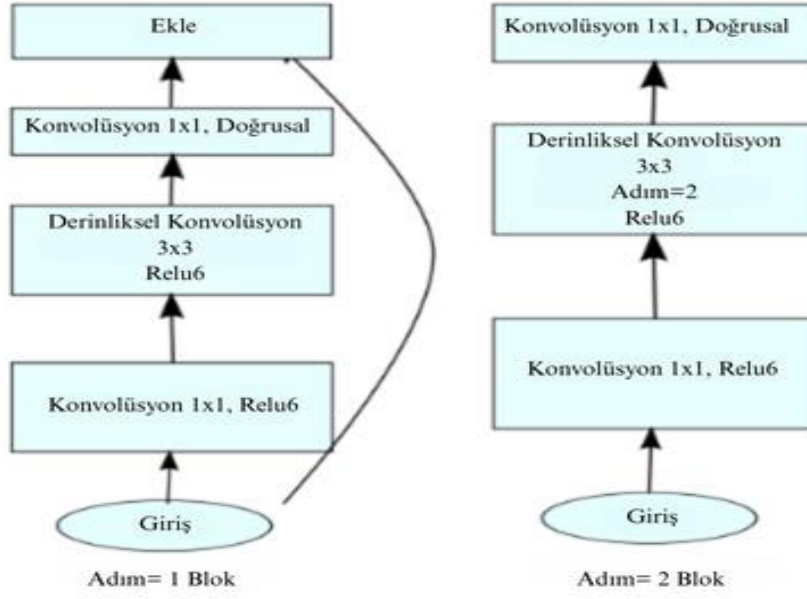
Inception V3, Google tarafından geliştirilen ve Inception mimarisi ailesine bağlı üçüncü versiyon derin bir sinir ağıdır. Literatürde ortaya konan modeller gibi temel amacı yüksek genelleme performansına sahip ve hesaplama maliyeti daha az olan bir model geliştirmektir. Inception V3 modeli ImageNet veri seti üzerinde test edilmiş ve rakiplerine oranla daha yüksek bir başarı göstermiştir. Inception ailesinin versiyon-1 ve versiyon-2 modellerine göre daha derin bir ağa sahip olmakla beraber daha iyi bir hesaplama optimizasyonuna sahiptir. Model, farklı boyutlardaki filtreleri aynı anda kullanılarak çoklu ölçekte veri üzerinden özellik çıkartmada oldukça başarılıdır. Model girdileri 3 kanallı ve 299x299 piksel boyutundadır. Modelde aktivasyon fonksiyonu olarak softmax kullanılmıştır. Maksimum havuzlama ve ortalama havuzlama katmanları birlikte kullanılmıştır. Modelin aşırı öğrenmesinin de önüne geçmek amacıyla düğüm bırakma (dropout) eklenmiştir. Model, faktörize konvolüsyonlar, verimli boyut küçültme teknikleri ve yardımcı sınıflandırıcılar ile önemli yenilikler sunmaktadır. Medikal uygulamalarda özellikle veri sayısının az olduğu durumlarda model, transfer öğrenme yaklaşımıyla kullanılarak sınıflandırma vb. problemlerin çözümünü sağlamaktadır. Inception temel mimarisinin diğer versiyonlarına göre birtakım farklılıklar sunmaktadır ve incele ayarlama (fine tuning) işlemi yapılmış olup toplu normalizasyon (batch normalization) ile desteklenen tekniklerle model performansı artırılmıştır. İlgili mimaride farklı boyutlardaki filtreler (1x1, 3x3, 5x5) paralel olarak kullanılmış ve farklı ölçeklerdeki özelliklerin tespit edilmesi sağlanmıştır. Büyük boyutlu filtrelerin yerine ardışık küçük boyutlu filtrelerin kullanılması hesaplama maliyetini azaltmıştır. Toplu normalizasyon ile ağ daha hızlı ve dengeli öğrenmiştir. Ağın ara katmanlarına eklenen yardımcı sınıflandırıcılarla eğitimde daha hızlı geri yayılım ve düzenleme sağlanmıştır. Mimaride konvolüsyonlar 1x7 ve 7x1 olarak uygulanmış ve hesaplama yükünün azaltılması hedeflenmiştir. Toplu normalizasyon dışında optimizasyon ve RMSprop da çalışmada kullanılmıştır [57]. Şekil 5.10'da kullanılan mimari diyagramda gösterilmiştir.



Şekil 5.10. Inception V3 Mimarisi

5.4.3. MobileNet V2

Geliştirilen modellerin mobil ve web tabanlı uygulamalar ile entegrasyonu oldukça önemlidir. Uygulamalar mobil cihazlar üzerinde fazla yer kapladığında veya performans yeterliliklerine sahip olmadıklarında kullanıcılar için problemler oluşmaktadır ve yapay zekâ tabanlı uygulamaların da bu gerekliliklere özen göstermesi gerekmektedir. İlgili mimarinin felsefesinin de bu amaç yatar. Girdi verisi 3 kanallı, 224x244 boyutundadır ve toplam 3x3 piksel boyutunda 32 adet çekirdek kullanılmıştır. Tersine Kalıntı Bloğu (Invert Residual Block) tarafında her blok genişletme, derinlik ayrılabilir evrişim ve projeksiyon aşamalarını içermektedir. Genişletme aşamasında 1x1 boyutunda filtreler ile evrişim işlemi uygulanmıştır. İşlem sonrası kanal sayısı artmıştır. Aktivasyon fonksiyonu olarak ReLU6 kullanılmıştır. Derinlik ayrılabilir evrişim işleminde her kanala ayrı ayrı 3x3 boyutunda filtre uygulanmış ve her kanaldaki özellik haritası içerisinde uzamsal desenler öğrenilmiştir. ReLU6 aktivasyon fonksiyonu bu blokta da yer almıştır. Projeksiyon aşamasında ise 1x1 boyutunda filtreler ile konvolüsyon işlemi yapılmış; ancak aktivasyon fonksiyonu kullanılmamıştır. Bu katmanda bilgi doğrudan taşınmıştır. MobileNet mimarisi ile gradyan akışı kolaylaşmaktadır [58]. Şekil 5.11’de orijinal makaleden alınmış modelin mimari tasarımı ile ilgili blok diyagram yer almaktadır.



Şekil 5.11. MobileNet V2 Mimarisi

5.4.4. DenseNet-121

DenseNet-121 mimarisi yoğun bağlantılı mimarisiyle öne çıkmaktadır ve kendi versiyonu içerisinde öncül bir modeldir. İleri yıllarda tanıtılan daha yüksek katmanlı ve daha derin DenseNet modelleri yer almaktadır. Modelin temel felsefesi; her katman, kendisinden önce gelen tüm katmanların özellik haritalarını (feature map) girdi olarak almaktadır. İlgili süreç sonucunda gradyan sönmesi (vanishing gradient) sorunu azalır, parametre sayısı azaltılarak hesaplama verimliliği de arttırılmaktadır. DenseNet-121 modelinde girdi verileri 3 kanallı, 224x224 piksel boyutundaki görsellerdir. Girişi bloğunda 7x7 boyutundaki 64 adet filtre kullanılarak evrişim işlemi yapılır ve 3x3 boyutundaki filtrelerle de maksimum havuzlama operasyonu uygulanmaktadır. Modelin özgün ve temel noktalarından birisi de yoğun bloklara (dense blocks) sahip olmasıdır. Modelde toplamda 4 adet yoğun blok yer almaktadır. içermektedir. Yoğun blokların içerisinde darboğaz katmanları (bottleneck layers) bulunmaktadır. İlk blokta 6, ikinci blokta 12, üçüncü blokta 24 ve son blokta da 16 adet darboğaz katmanı bulunmaktadır. Her darboğaz katmanında 1x1 ve 3x3 boyutlarında evrişim işlemleri yapılmaktadır. Yoğun katmanlar arasında da geçiş katmanları (transition layers) yer almaktadır ve geçiş katmanı içerisinde 1x1 evrişim ve 2x2 boyutlarındaki filtreler ile de ortalama havuzlama işlemi yapılmaktadır. Modelin son aşamasında ortalama

havuzlama, tam bağlantılı katman ve çok sınıflı bir problemi çözmek adına da aktivasyon fonksiyonu olarak softmax kullanılmıştır [59].

5.4.5. DenseNet-169

DenseNet-169 mimarisi de DenseNet-121 mimarisine benzer yapıdadır; ancak aralarındaki fark yoğun bloklar içindeki katman sayısından oluşmaktadır. Girdi verileri 3 kanallı, 224x224 piksel boyutundadır. DenseNet-169 mimarisinde başlangıç katmanında konvolüsyon işleminde 7x7 piksel boyutunda 64 adet filtre kullanılmaktadır. Kaydırma (stride) parametresi 2 olarak ayarlanmıştır. Evrişim işlemini havuzlama işlemi takip etmiş ve 3x3 boyutunda filtre özelinde 2 piksel kaydırma uygulanarak maksimum havuzlama yapılmıştır. Toplam 4 adet yoğun katmandan meydana gelmektedir. Geçiş katmanlarında 1x1 konvolüsyon ve 2x2 filtreler ile ortalama havuzlama işlemi uygulanmıştır. DenseNet-169 mimarisinin ilk yoğun bloğunda 6, ikinci yoğun bloğunda 12, üçüncü yoğun bloğunda 32 ve son bloğunda da 32 adet darboğaz katmanı yer almaktadır. Toplam 169 adet yoğun katmandan oluşmaktadır. DenseNet-121 modeline göre son iki yoğun blokta daha fazla katman içermektedir [59].

5.4.6. DenseNet-201

DenseNet-201 mimarisi de DenseNet-121 ve DenseNet-169 mimarilerine benzer yapıdadır; ancak aralarındaki fark yoğun bloklar içindeki katman sayısından oluşmaktadır. Mimari yapının genel tasarımı, kullanılan katman türleri ve bağlantı şekilleri birbirleriyle aynıdır. İlk yoğun blok içerisinde 6 katman, ikinci yoğun blok içerisinde 12 katman, üçüncü yoğun blok içerisinde 48 katman ve son yoğun blok içerisinde de 32 adet darboğaz katmanı yer almaktadır. Geçiş katmanları tek katman olarak işlem görmektedir. Yoğun katmanlar arasında da geçiş katmanları (transition layers) yer almaktadır ve geçiş katmanları içerisinde 1x1 evrişim ve 2x2 boyutlarındaki filtreler ile de ortalama havuzlama işlemi yapılmaktadır. Modelin derin olmasından dolayı özellik çıkarımı performansı DenseNet-121 ve DenseNet-169 göre daha yüksektir. Karmaşık ve büyük veri setlerinde daha iyi performans gösterebilir. Parametre sayısı ve hesaplama gereksinimi diğer modellere göre daha fazladır [59].

5.4.7. VGG-16

Alex-Net mimarisi 2012 yılında tanıtıldıktan sonra derin öğrenme dünyasında literatür çalışmaları hız kazanmıştır. VGG mimarisi, 2014 yılında Oxford Üniversitesi'nde Karen Simonyan ve Andrew Zisserman tarafından geliştirilmiştir. VGG mimarisi ile katman derinliği arttırılarak görüntü tanıma problemlerinde yüksek başarı elde etmek hedeflenmiştir. Özellikle küçük filtreler kullanılarak görüntüler üzerinden fazla özellik çıkartmak amaçlanmıştır. Giriş görüntüleri 3 kanallı, 224x224 boyutlarındadır. Toplam 5 adet konvolüsyon bloğu ve tam bağlantılı katmandan oluşmaktadır. Modelde 13 adet evrişim katmanı yer almaktadır. İlk konvolüsyon bloğunda 2 adet konvolüsyon katmanı, 3x3 boyutunda 64 adet filtre kullanılmıştır. İkinci konvolüsyon bloğunda 2 adet konvolüsyon katmanı, 3x3 boyutunda 128 adet filtre kullanılmıştır. Aktivasyon fonksiyonları ReLU'dur ve maksimum havuzlama operasyonu da evrişim işleminin beraberinde kullanılmıştır. Üçüncü konvolüsyon bloğunda 3 adet konvolüsyon katmanı aynı boyutta 256 adet filtre kullanılmıştır. Dördüncü konvolüsyon bloğunda 3 adet konvolüsyon katmanı, 512 adet 3x3 boyutunda filtre ve diğer katmanlarda olduğu gibi ReLU aktivasyon fonksiyonu ve maksimum havuzlama operasyonu kullanılmıştır. Son konvolüsyon bloğunda 3 adet konvolüsyon katmanı yer almış ve toplam 3x3 piksel boyutlarında 512 adet filtre yer almıştır. Tam bağlantılı katmanda ise düzleştirme katmanı sonra 2 adet tam bağlantılı katma ve çıktı katmanı yer almaktadır. Mimaride 3 adet tam bağlantılı katman yer almaktadır. Modelde tüm evrişim katmanından sonra ReLU aktivasyonu fonksiyonu yer almaktadır. Parametre sayısı oldukça fazladır [60].

5.4.8. VGG-19

VGG-19 mimarisi, 2014 yılında Oxford Üniversitesi'nden Karen Simonyan ve Andrew Zisserman tarafından geliştirilen VGG ailesinin bir üyesidir. VGG-19, daha derin bir yapı sunarak özellikle küçük boyutlu filtreler (3x3) aracılığıyla detaylı özellik çıkarımı yapmayı hedeflemektedir. Modelin girişinde 3 kanallı ve 224x224 boyutlarında RGB görüntüler yer almaktadır. VGG-19 mimarisi toplamda 5 konvolüsyon bloğundan ve 3 tam bağlantılı (fully connected) katmandan oluşmaktadır. Modelde toplam 16 adet evrişim katmanı ve 3 adet tam bağlantılı katman olmak üzere 19 katman bulunmaktadır (sadece öğrenilebilir katmanlar sayıldığında). Birinci konvolüsyon bloğunda, 2 adet 3x3 boyutunda ve 64 adet filtreye sahip evrişim katmanı yer almakta; ardından ReLU aktivasyon fonksiyonu

ve 2x2 boyutunda maksimum havuzlama (max pooling) uygulanmaktadır. İkinci konvolüsyon bloğunda, 2 adet 3x3 boyutunda ve 128 adet filtreye sahip evrişim katmanı bulunmakta; yine ReLU aktivasyonu ve maksimum havuzlama işlemi gerçekleştirilmektedir. Üçüncü blokta, 4 adet 3x3 boyutunda ve 256 adet filtreye sahip evrişim katmanı bulunmaktadır. Tüm katmanlardan sonra ReLU aktivasyonu ve ardından maksimum havuzlama uygulanmaktadır. Dördüncü blokta, 4 adet evrişim katmanı 512 adet 3x3 filtre ile birlikte kullanılmakta, her biri ReLU aktivasyonu ile tamamlanmakta ve ardından maksimum havuzlama yapılmaktadır. Beşinci konvolüsyon bloğunda da yine 4 adet 3x3 boyutunda, 512 filtrelili evrişim katmanı bulunmakta; ReLU aktivasyonları ve maksimum havuzlama işlemi ile blok sonlandırılmaktadır. Evrişim bloklarının ardından gelen tam bağlantılı kısımda, düzleştirme (flatten) işlemi yapılır. Ardından sırasıyla 4096 nörona sahip 2 adet tam bağlantılı katman (ReLU aktivasyonlu) ve 1000 sınıfa yönelik softmax aktivasyonlu çıktı katmanı yer almaktadır. [60].

5.4.9. Meta Model

Bu çalışmada, toplam 8 adet önceden eğitilmiş derin öğrenme modeli kullanılarak ince ayarlama (fine tuning) konfigürasyonu ile veri setimiz üzerinde eğitim, doğrulama ve test işlemleri gerçekleştirilmiştir. Test seti üzerinde yapılan detaylı performans analizi sonucunda DenseNet mimarilerinin yapısı ve derin katman mimarisinden dolayı veri setimiz üzerinde genelleme yeteneğinin oldukça yüksek olduğu görülmüştür. Xception mimarisi de başarılı bir tahminleme performansı sergilemiştir. Eğitilmiş DenseNet169, DenseNet201 ve Xception derin öğrenme modellerinin özellik çıkarma katmanlarından elde edilen vektörleri bir araya getirilip özellik düzeyi yığılma topluluk öğrenmesi yaklaşımıyla yeni bir “meta model” oluşturulmuştur. Meta modelin eğitimi, validasyon ve test işlemleri gerçekleştirilmiştir ve yeni güçlü model, ayrı modellere göre daha yüksek sınıflandırma başarısı göstermiştir. 5 aşamada algoritma adımları özetlenmiştir.

1. Algoritmanın ilk aşamasında NumPy, Matplotlib, Scikit-Learn kütüphaneleri programa dahil edilmiştir ve daha önceden eğitilen ve ağırlık dosyaları Google Drive üzerinde yer alan DenseNet169, DenseNet201 ve Xception modelleri load_model fonksiyonu ile programa dahil edilmiştir. Sonrasında “tf.keras.preprocessing.image.ImageDataGenerator” ile görüntü pikselleri 0–1 aralığına yeniden ölçeklenmektedir (rescale=1./255). Ardından flow_from_directory fonksiyonu üç ayrı klasörden (train3, val3, test3) sırasıyla eğitim,

doğrulama ve test veri setlerini oluşturmak için kullanılmaktadır. Her biri 224×224 boyutunda yeniden şekillendirilen görüntüler, 32'lik partiler hâlinde yüklenmektedir ve ikili sınıflandırma için etiketlenmektedir.

2. DenseNet201, DenseNet169 ve Xception modelleri için en zengin özellik çıkarma katmanı belirlenmektedir. Model katman haritası çıkarıldıktan sonra tam bağlantılı katman öncesinde veri ile ilgili yüksek seviye bilgi taşıyan “global_average_pooling” katmanı çıktısı özellik vektörü olarak üç model için de belirlenmiştir. İlgili konvolüsyon katmanındaki özellik haritalarının ortalamalarını alarak (None, 1920) boyutunda özellik vektörü DenseNet201, (None, 1664) DenseNet169 ve (None, 20248) Xception en yüksek seviye bilgiyi barındırmaktadır. İlgili diğer çalışmada VGG16 ve ResNet50V2 modellerinin GAP katmanından alınan özellik vektörlerinin birleştirilmesiyle geliştirilen modelin ayrı ayrı modellere göre daha iyi tahminleme performansı gösterdiği ve test doğruluğunun da %95.00 olduğu deneysel olarak ispatlanmıştır [71]. Bu çalışmada GAP katmanının özellik vektörü seçiminde kullanılmasının diğer bir referansı da tam bağlantılı katmanının yerine küresel ortalama havuzlama (global average pooling) yöntemini içeren makalede yer almaktadır. Makaledeki fikir, sınıflandırma görevindeki her kategoriye karşılık gelen bir özellik haritası üretmektir. Özellik haritalarının üzerine fully connected katman eklemek yerine, her özellik haritasının ortalaması alınmaktadır ve ortaya çıkan vektör doğrudan softmax katmanı ile bağlanmaktadır [72].

3. DenseNet201, DenseNet169 ve Xception'dan çıkarılan özellik vektörleri alınır ve her bir dalda Yoğun Katman (Dense layer), Toplulaştırma Katmanı (BatchNormalization), Sızıntılı Doğrusal Birim (LeakyReLU) ile Bırakma (Dropout) işlemleri uygulanır; ardından Kısa Yol (Residual) bağlantıları ile bu dalları zenginleştirir. Daha sonra üç dalın çıktıları Birleştirme (Concatenate) ile tek bir vektörde toplanır ve ardışık yoğun katmanlar ile Bırakma (Dropout) katmanlarından geçirilir. En sonunda tek nöronlu ve sigmoid aktivasyonu (sigmoid activation) kullanan bir çıkış katmanı ile ikili sınıflandırma sonucu üretilir. Model, AdamW Optimizatörü (AdamW optimizer), Erken Durdurma (EarlyStopping), Öğrenme Oranını Azaltma (ReduceLRonPlateau) ve Model Kaydetme (ModelCheckpoint) geri çağırımları (callbacks) ile derlenip eğitilerek güçlü bir topluluk öğrenmesi (ensemble learning) sınıflandırıcısına (meta model) dönüştürülür.

4. Özellik düzeyinde topluluk öğrenmesi yaklaşımı ile geliştirilen model (meta model), algoritmada yer alan hiperparametre değerleri (döngü=100, yığın boyutu=32, öğrenme oranı= 0.0005, düşürme oranı=0.3, 0.4, 0.5) ile eğitilmiş ve sonrasında test seti ile test edilerek, performans metrik sonuçları incelenmiştir.

5.5. Model Değerlendirmesinde Kullanılan Performans Metrikleri

Yapay zekâ dünyasında modelin sadece eğitim sırasında değil; eğitim sonrasında da gerçek dünyada performans ölçümünün yapılması gerekmektedir. Tüm performans ölçütleri modelin farklı yeteneklerinin değerlendirilmesini sağlamaktadır. Doğruluk (accuracy) sınıflandırıcının genel performansını ortaya koyar. Kesinlik (precision) kavramı ise sınıflandırıcının pozitif olarak tahmin ettiği örneklerden kaç tanesinin gerçekten pozitif olduğunu göstermektedir. Duyarlılık değeri (Recall), sınıflandırıcının doğru pozitif olarak bulduğu örnek sayısının doğru pozitif ve yanlış negatif örneklere bölünmesiyle elde edilmektedir ve sınıflandırıcının, tüm gerçek pozitifleri ne kadar başarıyla bulabildiğini göstermektedir. F1 Skoru ölçütü ise verinin pozitif etiketleri ile bir sınıflandırıcı tarafından verilen etiketler arasındaki ilişkileri belirlemek amacıyla kullanılmaktadır. AUC Skoru ise sınıflandırıcının yanlış sınıflandırmadan kaçınma yeteneğini ortaya koymaktadır [61].

5.5.1. Doğruluk (Accuracy)

Doğruluk, modelin tüm tahminlerinin yüzde kaçının doğru olduğunu gösteren bir değerlendirme ölçütüdür. Modelin doğruluk ölçütü, doğru pozitif (true positive) ve doğru negatif (true negative) örneklerin toplamının tüm örneklerin toplamına oranı ile bulunmaktadır. Modelin sınıfları ne ölçüde doğru tahmin edebildiği gösterilmektedir. Doğruluk değerinin isabetli hesaplanmasında veri setinin dengeli olması oldukça önemlidir. Dengesiz veri setlerinde doğruluk değeri istenildiği şekilde hesaplanamayabilir [23].

$$\text{Doğruluk} = (TP + TN) / (TP + TN + FP + FN) \quad (5,9)$$

5.5.2. Kesinlik (Precision)

Kesinlik (precision), sistemin pozitif olarak tahmin ettiği örnekler arasından, gerçekten pozitif olanların oranıdır. Doğru pozitif (true positive) örneklerin, doğru pozitif (true positive) ve yanlış pozitif (false positive) örneklerin toplamına oranıdır [61]. Kesinlik değerinin 1'e yakın olması modelin ne kadar doğru sınıflandırdığını göstermek için önemli bir ölçüttür.

$$\text{Kesinlik} = (\text{TP}) / (\text{TP} + \text{FP}) \quad (5,10)$$

5.5.3. Duyarlılık (Recall)

Duyarlılık değeri, modelin tahminlediği gerçek pozitif (true positive) örneklerin, gerçek pozitif (true positive) ve yanlış negatif (false negative) örneklerin toplamına oranıdır. Modelin pozitif etiketleri ne derece etkili tanımlayabildiğinin bir ölçüsüdür. Aşağıda formülü gösterilmektedir [61].

$$\text{Duyarlılık} = (\text{TP}) / (\text{TP} + \text{FN}) \quad (5,11)$$

5.5.4. F1 skoru (F1 Score)

F1 skoru, kesinlik (precision) ile duyarlılık (recall) metriklerinin harmonik ortalamasıdır. Doğruluk performans metriği dengesiz veri kümelerinde model performansını değerlendirmede fazlasıyla etkili değildi; ancak f1 skoru, dengesiz veri kümelerinde model performansını değerlendirmede kullanılmaktadır. F1 skorunun formülasyonu aşağıda gösterilmiştir [61].

$$\text{F1 Skoru} = 2 \times [(\text{Hassasiyet} \times \text{Duyarlılık}) / (\text{Hassasiyet} + \text{Duyarlılık})] \quad (5,12)$$

5.5.5. Karışıklık matrisi (confusion matrix)

Karışıklık matrisi, modelin değerlendirilmesinde kapsamlı ve faydalı bir göstergedir. Çok sınıflı veya ikili sınıflandırma problemlerinde literatürde model performansını değerlendirmek amacıyla kullanılır. Karışıklık matrisinde gerçek etiketler ile tahmin edilen etiketlerin sayısal oranları verilmektedir. [63].

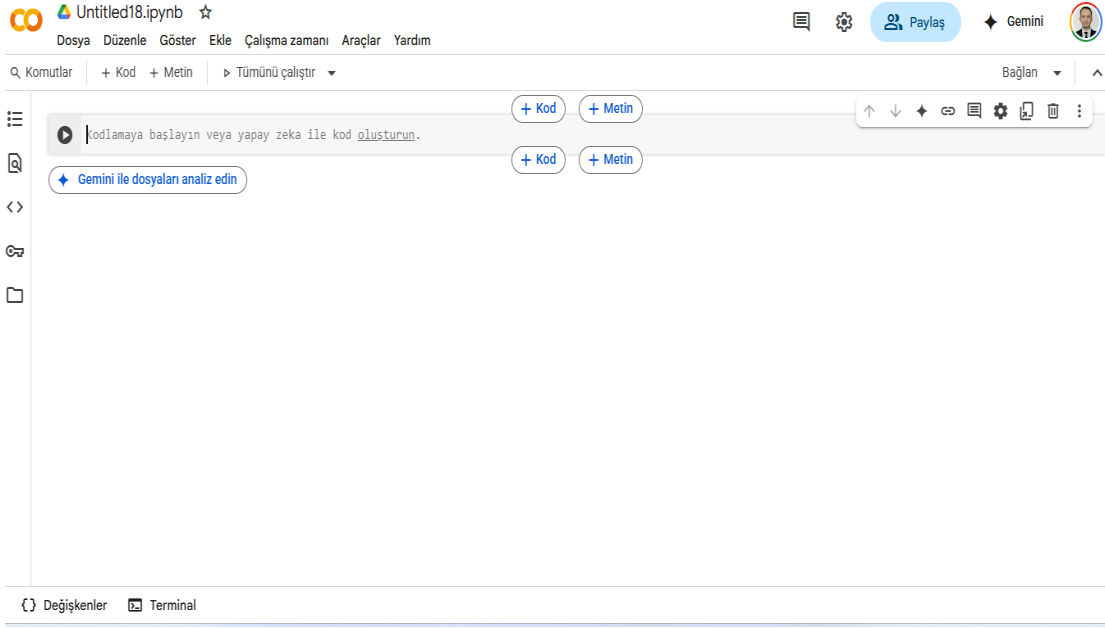
6. BULGULAR VE TARTIŞMA

Bu çalışmada, 8 farklı derin öğrenme modeli ve hibrit bir model kullanılarak maymun çiçeği hastalığının cilt görüntüleri üzerinden tespit edilmesi amaçlanmıştır. Tüm modellerin tahminleme becerileri detaylı performans metrikleri ile karşılaştırılmış ve meta modelin, ayrı ayrı modellere göre başarısı gösterilmiştir. Eğitim çalışmaları Google Colab Pro ortamında gerçekleştirilmiştir. Google Colab Pro, Colab ortamının ücretli sürümüdür. Kullanıcılara daha güçlü GPU destekleri sunmaktadır. Özellikle kullanıcılara yüksek işlem gücü, daha uzun çalışma süresi ve daha az bekleme süresi sunmaktadır. Bu çalışmada, NVIDIA Tesla T4 GPU kullanılmıştır. GPU mimarisi NVIDIA Turing (TU104)'tür ve GPU Belleği (16 GB GDDR6) 'dır. Bellek bant genişliği 320 GB/s'dir. CUDA çekirdek sayısı 2.560'dır. Aşağıda kullanılan NVIDIA Tesla T4 GPU özellikleri gösterilmektedir.

Özellik	Açıklama
GPU Mimarisi	NVIDIA Turing (TU104)
GPU Belleği	16 GB GDDR6
Bellek Bant Genişliği	320 GB/s
TDP (Güç Tüketimi)	70 W
CUDA Çekirdekleri	2,560
Tensor Çekirdekleri	320
FP32 Performansı	~8.1 TFLOPS
INT8 Performansı	~130 TOPS
Bağlantı Arayüzü	PCIe 3.0 x16
Soğutma	Pasif (sunucu için)

Şekil 6.1. NVIDIA Tesla T4 GPU Özellikleri

Google Colab Pro üzerinde hücresele çalıştırma prensibiyle python programlama dili kullanılarak çalışma gerçekleştirilmiştir. Tüm modellerin algoritmaları ayrı ayrı olarak oluşturulmuş olup kaynak kodları da Google Drive üzerine kaydedilmiştir. Bilgisayarlı görü ve görüntü işleme kütüphaneleri hazır olarak çalışmaya dahil edilmiştir. Programın üç temel avantajı yer almaktadır. Jupyter notebook tabanlı olduğu için hücresele olarak programın takibinin kolaylıkla sağlanması ve hataların sistematik bir şekilde izlenmesi, güçlü donanım özelliklerine bulut ortamı üzerinden erişilebilmesi ve kütüphanelerin büyük çoğunluğunun programda hazır olması ve/veya kolaylıkla programa dahil edilmesi olarak ifade edilebilir. Çalışma sırasında kullanılan Google Colab ortamı aşağıda gösterilmiştir.



Şekil 6.2. Google Colab Geliştirme Ortamı

Çalışmada farklı kaynaklardan elde edilen veri setleri birleştirilerek tümleşik bir veri seti elde edilmiştir. Tümleşik veri setindeki duplike olan imajlar silinmiş veri artırma tekniği ile veri sayısı arttırılmış ve maymun çiçeği, maymun çiçeği olmayan olmak üzere iki klasörde veriler toplanmıştır. Maymun çiçeği pozitif sınıfında yer alan toplam 3682 veri bulunmaktadır. Maymun çiçeği, suççiçeği, kızamık, normal cilt görüntülerinden oluşan dosyada ise 4851 adet cilt görüntüsü yer almaktadır. Bu bağlamda matematiksel olarak sınıfların dengeli olduğu gözükmemektedir. Kafes Arama (Grid Search) yöntemiyle yapılan inceleme sonucunda veriler %81 eğitim (train3), %9 validasyon (val3) ve %10'da test seti (test3) olarak ayrılmıştır. Tüm klasör, dosya ve imajlar Google Drive platformu üzerinde kaydedilmiş ve algoritmaya da dosya yolları ile çekilerek kullanılmıştır.

Adı ↑	Sahibi	Değiştirilme tarihi	Dosya boyut	
monkeypox	ben	14 Eki 2024	—	⋮
nonmonkeypox	ben	14 Eki 2024	—	⋮
test3	ben	21 Kas 2024	—	⋮
train3	ben	21 Kas 2024	—	⋮
val3	ben	21 Kas 2024	—	⋮

Şekil 6.3. Çalışmada Kullanılan Veritabanı

6.1. VGG16 Modeli Deneysel Çıktılar & Analiz Sonuçları

VGG16 derin öğrenme modeli AlexNet sonrasında ortaya çıkmış en güncel derin modellerden birisidir. Güncel derin öğrenme modellerine de örnek teşkil etmektedir. Bu çalışmada VGG16 modeli transfer öğrenme yaklaşımı ile kullanılmıştır. Toplam veri setinin %90'ı eğitim, %10'u test veritabanı olarak ayrıldıktan sonra eğitim veri setinin de %10'u da doğrulama veri seti olarak ayrılmıştır. Toplam verilerin 6911 adeti eğitim, 768 adeti doğrulama ve 854 adeti de test amaçlı kullanılmıştır.

Tablo 6.1. VGG16 Veri Dağılımı

Veri Türü	Yüzde (%)
Eğitim	81
Validasyon	9
Test	10

Modelin eğitimi sırasında kullanılan hiperparametre değerleri aşağıdaki tabloda gösterilmektedir. Çalışma boyunca modelin tüm eğitim verisi üzerinde 100 kere eğitilmiştir. Her seferde eğitime alınan örnek sayısı 32 olarak belirlenmiştir. Ağırlıkların güncellenme hızı 0.0001'dir. Aşırı öğrenmeyi önlemek için nöronların rastgele devre dışı bırakılma oranı 0.5 olarak belirlenmiştir. Modelin hangi olasılıkla bir sınıfa karar verdiğini belirleyen eşik 0.50 olarak algoritma analizi sonucunda optimal belirlenmiştir. Tam bağlantılı katmandaki nöron sayısı ise 256'dır.

Tablo 6.2. VGG16 Hiperparametre Değerleri

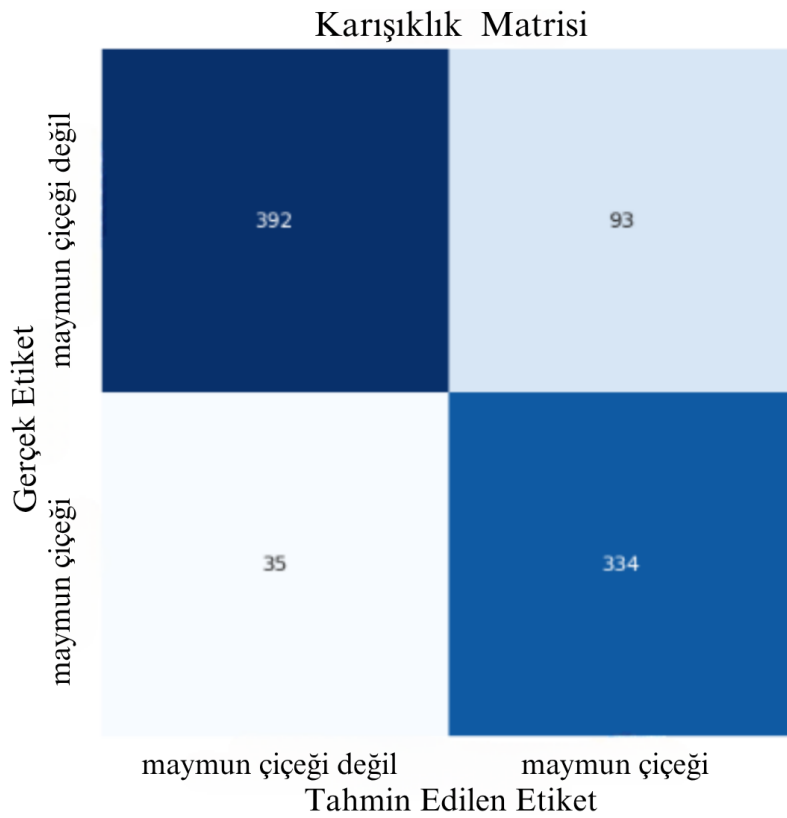
Döngü	Yığın Boyutu	Öğrenme Oranı	Düşürme (Dropout)	Eşik Değeri	Nöron Sayısı
100	32	0.0001	0.5	0.50	256

Tablo 6.3.'de VGG16 modelinin eğitim sonrası test veri seti üzerinde değerlendirmesiyle detaylı performans analizleri sunulmuştur. Model, sınıf 0 (maymun çiçeği olmayan) için %91.59 kesinlik ($tp / (tp + fp)$) ve %80.82 duyarlılık (gerçek pozitifleri iyi tahmin etme) ile oldukça başarılı tahminlerde bulunmuş; sınıf 1 (maymun çiçeği) için ise %78.17 kesinlik ve %90.24 duyarlılık elde etmiştir. Bu değerler, modelin her iki sınıfı da dengeli şekilde ayırt edebildiğini göstermektedir. Makro ortalama değerler (sınıflar arası eşit önem varsayılarak): %84.82 F1 skoru ile yüksek genel performansa işaret ederken; ağırlıklı ortalamalar da %84.96 F1 skoru, modelin veri dağılımına duyarlı şekilde iyi çalıştığını doğrulamaktadır. Özellikle %84.89'lik genel doğruluk oranı, modelin test setindeki örneklerin büyük kısmını doğru şekilde sınıflandırdığını göstermektedir. Eşik değeri, ROC eğrisi üzerinde en iyi ayırım yapan noktayı Youden's J istatistiği yöntemiyle vermektedir. Kayıp (loss) değerinin 0.3449 gibi düşük bir seviyede olması, modelin gerçek ve tahmin edilen etiketlerinin büyük oranda örtüştüğünü ve de modelin eğitim sırasında iyi optimize edildiğini ortaya koymaktadır. Genel olarak değerlendirildiğinde, model yüksek başarı, dengeli sınıf tahminleri ve düşük kayıpla güvenilir bir sınıflandırıcı olarak öne çıkmaktadır.

Tablo 6.3. VGG16 Sınıflandırıcı Performans Çıktıları


Sınıf	Kesinlik	Duyarlılık	F1 Skoru	Veri Sayısı
0	0.9159	0.8082	0.8587	485
1	0.7817	0.9024	0.8337	369
Makro Ortalama	0.8488	0.8553	0.8482	854
Ağırlıklı Ortalama	0.8579	0.8489	0.8496	854
Genel Model Doğruluğu	0.8489 - %84.89			
Genel Model Kesinliği	0.8579			
Genel Model Duyarlılığı	0.8489			
Genel Model F1 Skoru	0.8496			
Eşik Değeri	0.5015			
Kayıp Değeri	0.3449			
Model Boyutu	57.73 MB			
Eğitim Süresi	2 saat, 16 dakika, 45 saniye			
Donanım Özellikleri	NVIDIA Tesla T4 GPU 16 GB RAM GDDR6 SDRAM Technology 2560 CUDA Cores 320 GBps Bandwith			

VGG16 modelinin test verisi üzerindeki karışıklık matrisi (confusion matrix) Şekil 6.4.'de gösterilmiştir. Toplamda 854 adet veriden oluşan örneklem içerisinde 392 görüntü, hem gerçekte sınıf “0” olup hem de model tarafından doğru şekilde sınıf “0” olarak tahmin edilmiştir. 93 görüntü gerçekte sınıf “0” olmasına rağmen model tarafından yanlışlıkla sınıf “1” olarak sınıflandırılmıştır. Toplam 35 görüntü ise gerçekte sınıf “1” olmasına rağmen model tarafından hatalı şekilde sınıf “0” olarak tahmin edilmiştir. Öte yandan, 334 görüntü, hem gerçekte sınıf “1” olup hem de doğru şekilde model tarafından sınıf “1” olarak sınıflandırılmıştır. Bu doğrultuda, doğru negatif (true negative) örnek sayısı 392, yanlış pozitif (false positive) sayısı 93, yanlış negatif (false negative) sayısı 35 ve doğru pozitif (true positive) örnek sayısı 334’tür. Yanlış pozitif oranı %10.89, yanlış negatif oranı da %4.10’dur. Bu sonuçlar, modelin hem negatif hem de pozitif sınıfları optimum seviyede doğrulukla ayırt edebildiğini göstermektedir.



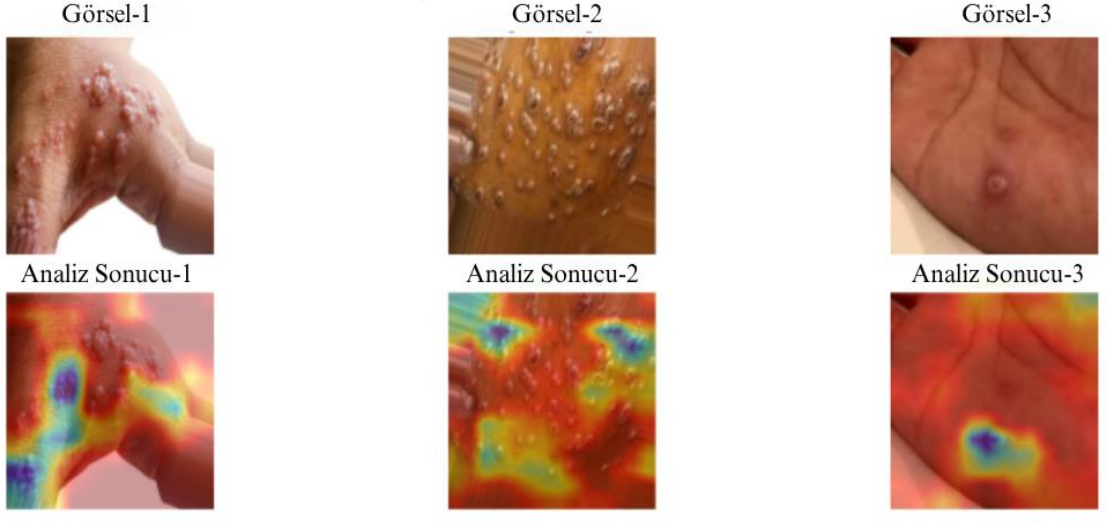
Şekil 6.4. VGG16 Karışıklık Matrisi

VGG16 modelinin doğruluk/kayıp grafiği Şekil 6.5.'de incelendiğinde eğitim ve validasyon doğruluğunun ilk döngüden itibaren yükseldiği gözlemlenmiştir. Döngü sonlarında modelin validasyon seti üzerindeki doğruluğu %80 seviyesinin üzerine çıkmıştır. Eğitim ve validasyon doğruluk eğrileri de birbirine yakın seyretmiştir. Eğitim ve validasyon verisi üzerinde döngü boyunca kayıp oranı azalmış ve sıfıra doğru yaklaşmıştır. Modelin eğitim ve validasyon seti üzerindeki genelleme yeteneğinin iyi olduğu gözükmektedir.



Şekil 6.5. VGG16 Doğruluk Kayıp Grafikleri

Grad-CAM (Gradient-weighted Class Activation Mapping), derin öğrenme modellerinin, özellikle de konvolüsyonel sinir ağlarının (CNN) karar verme süreçlerini görselleştirmek için kullanılan bir tekniktir. Bu yöntem, modelin belirli bir sınıf için yaptığı tahminlerde hangi bölgelere odaklandığını anlamamıza yardımcı olur. Şekil 6.6.'da test dosyası içerisinde rastgele seçilen üç örnek görüntü üzerinden, modelin sınıflandırma yaparken doğru bölgelere odaklandığı göstermektedir.



Grad-CAM Algoritması Analiz Çıktıları

Şekil 6.6. VGG16 Grad-CAM Analizi

6.2. VGG19 Modeli Deneysel Çıktılar & Analiz Sonuçları

VGG19, VGG16'ya ek olarak her konvolüsyon bloğunda 1'er katman daha içermektedir ve ek katmanlar nedeniyle zengin özellik çıkarımı için kullanılabilir. Bu çalışmada VGG19 modeli transfer öğrenme yaklaşımı ile kullanılmıştır. Toplam veri setinin %90'ı eğitim, %10'u test veritabanı olarak ayrıldıktan sonra eğitim veri setinin de %10'u da doğrulama veri seti olarak ayrılmıştır. Toplam verilerin 6911 adeti eğitim, 768 adeti doğrulama ve 854 adeti de test amaçlı kullanılmıştır.

Tablo 6.4. VGG19 Veri Seti Yüzde Dağılımı

Veri Türü	Yüzde (%)
Eğitim	81
Validasyon	9
Test	10

Tablo 6.5.'de görüldüğü üzere modelin eğitimi sırasında kullanılan hiperparametre değerleri aşağıdaki tabloda gösterilmektedir. Çalışma boyunca modelin tüm eğitim verisi üzerinde 100 kere eğitilmiştir. Her seferde eğitime alınan örnek sayısı 32 olarak belirlenmiştir. Ağırlıkların güncellenme hızı 0.0001'dir. Aşırı öğrenmeyi önlemek için nöronların rastgele devre dışı bırakılma oranı 0.5 olarak belirlenmiştir. Modelin hangi olasılıkla bir sınıfa karar verdiğini belirleyen eşik 0,52 olarak algoritma analizi sonucunda optimal belirlenmiştir. Tam bağlantılı katmandaki nöron sayısı ise 256'dır.

Tablo 6.5. VGG19 Hiperparametre Değerleri


Döngü	Yığın Boyutu	Öğrenme Oranı	Düşürme (Dropout)	Eşik Değeri	Nöron Sayısı
100	32	0.0001	0.5	0.52	256

Tablo 6.6'da VGG19 modelinin eğitim sonrası 854 örnekten oluşan test veri seti üzerindeki performans değerlendirmesi sunulmuştur. Model, sınıf 0 (maymun çiçeği olmayan) için %88.24 kesinlik (precision) ve %80.41 duyarlılık (recall) ile yüksek doğrulukta tahminlerde bulunmuş; sınıf 1 (maymun çiçeği) için ise %76.94 kesinlik ve %85.91 duyarlılık göstererek pozitif sınıfa karşı güçlü bir hassasiyet ortaya koymuştur. Bu performans, modelin iki sınıf arasında dengeli bir ayırım yapabildiğini göstermektedir. Makro ortalama değerler (her sınıfın eşit ağırlıkla değerlendirildiği durumda), %82.66 F1 skoru ile modelin genel olarak yüksek sınıflandırma başarısı sunduğunu ortaya koyarken; ağırlıklı ortalamalar (veri setindeki sınıf dağılımını dikkate alan ölçüm) üzerinden elde edilen %82.86 F1 skoru ise, modelin özellikle gerçek veri dağılımına duyarlı şekilde çalıştığını göstermektedir. Modelin genel doğruluk (accuracy) oranı %82.79 olarak hesaplanmıştır ve modelin doğru pozitif ve doğru negatif örnekleminin oldukça başarılı olduğunu göstermektedir. ROC eğrisi üzerinden Youden's J istatistiği yöntemiyle belirlenen eşik değeri 0.5227'dir. Test verisi üzerindeki kayıp (loss) değeri 0.3822 ile görece düşük bir seviyede kalmış, bu da modelin tahmin çıktıları ile gerçek etiketler arasında güçlü bir örtüşme sağladığını ve aşırı öğrenme (overfitting) göstermediğini ortaya koymaktadır. Model boyutu 77.99 MB olan VGG19, bu test işlemlerini NVIDIA Tesla T4 GPU üzerinde gerçekleştirmiştir.

Tablo 6.6. VGG19 Sınıflandırıcı Performans Çıktıları

Sınıf	Kesinlik	Duyarlılık	F1 Skoru	Veri Sayısı
0	0.8824	0.8041	0.8414	485
1	0.7694	0.8591	0.8118	369
Makro Ortalama	0.8259	0.8316	0.8266	854
Ağırlıklı Ortalama	0.8336	0.8279	0.8286	854
Genel Model Doğruluğu	0.8279 - %82.79			
Genel Model Kesinliği	0.8336			
Genel Model Duyarlılığı	0.8279			
Genel Model F1 Skoru	0.8286			
Eşik Değeri	0.5227			
Kayıp Değeri	0.3822			
Model Boyutu	77.99 MB			
Eğitim Süresi	2 saat, 24 dakika, 8 saniye			
Donanım Özellikleri	NVIDIA Tesla T4 GPU 16 GB RAM GDDR6 SDRAM Technology 2560 CUDA Cores 320 GBps Bandwith			

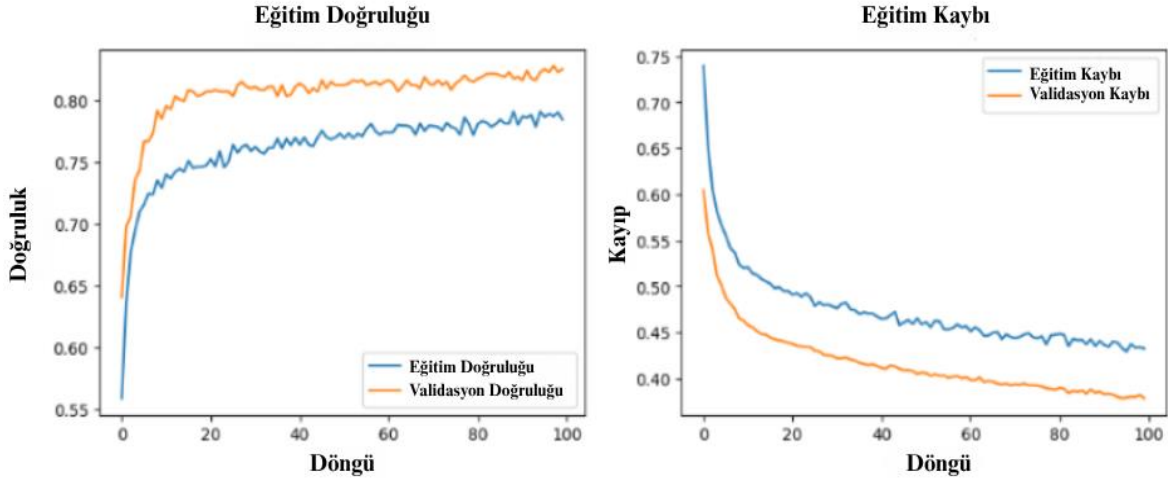
VGG19 modelinin test verisi üzerindeki karışıklık matrisi (confusion matrix) Şekil 6.7.'de gösterilmiştir. Toplamda 854 adet veriden oluşan örneklem içerisinde 378 görüntü, hem gerçekte sınıf “0” olup hem de model tarafından doğru şekilde sınıf “0” olarak tahmin edilmiştir. 107 görüntü gerçekte sınıf “0” olmasına rağmen model tarafından yanlışlıkla sınıf “1” olarak sınıflandırılmıştır. Toplam 45 görüntü ise gerçekte sınıf “1” olmasına rağmen model tarafından hatalı şekilde sınıf “0” olarak tahmin edilmiştir. Öte yandan, 324 görüntü, hem gerçekte sınıf “1” olup hem de doğru şekilde model tarafından sınıf “1” olarak sınıflandırılmıştır. Bu doğrultuda, doğru negatif (true negative) örnek sayısı 378, yanlış pozitif (false positive) sayısı 107, yanlış negatif (false negative) sayısı 45 ve doğru pozitif (true positive) örnek sayısı 324’tür. Yanlış pozitif oranı %12.53, yanlış negatif oranı da %5.27’dir. Bu sonuçlar, modelin hem negatif hem de pozitif sınıfları yüksek bir doğrulukla ayırt edebildiğini göstermektedir.



Şekil 6.7. VGG19 Karışıklık Matrisi


VGG19 modelinin doğruluk/kayıp grafiği Şekil 6.8’de incelendiğinde eğitim ve validasyon doğruluğunun ilk döngüden itibaren yükseldiği gözlemlenmiştir ve validasyon doğruluğu eğitim doğruluğunun bir miktar önündedir. Bu durum modelin aşırı öğrenme belirtisi göstermediğini ortaya koymaktadır. Model doğruluğu eğitim sonunda validasyon

tarafında %80 seviyesinin üzerine çıkmıştır. Eğitim ve validasyon verisi üzerinde döngü boyunca kayıp oranı azalmış ve sıfıra yakınsamıştır. Modelin eğitim ve validasyon seti üzerindeki genelleme yeteneğinin iyi olduğu gözükmemektedir.



Şekil 6.8. VGG19 Doğruluk Kayıp Grafikleri

Şekil 6.9’da Gradyan Ağırlıklı Sınıf Aktivasyon Haritalaması (Grad-CAM) ile orijinal görüntülerde lezyonun yer aldığı kısım, Grad-CAM çıktılarında da yoğun renkli (sıcak) bölgelerle vurgulanmıştır. Bu, modelin gerçekten hastalıklı bölgeye odaklandığını, rastgele arka plana değil lezyonun karakteristik özelliklerine baktığını göstermektedir.



Grad-CAM Algoritması Analiz Çıktıları

Şekil 6.9. VGG19 Grad-CAM Analizi

6.3. DenseNet121 Modeli Deneysel Çıktılar & Analiz Sonuçları

DenseNet 121 mimarisi 121 adet katmandan oluşan derin bir sinir ağıdır. Her katman, tüm önceki katmanların çıktılarını girdi olarak alarak gradyan akışını iyileştirir ve parametre verimliliğini artırır. Bu çalışmada DenseNet121, DenseNet169 ve DenseNet201 mimarileri ile transfer öğrenme yaklaşımıyla kullanılmıştır. Toplam veritabanının, %90'ı eğitim, %10'u test seti olarak ayrıldıktan sonra eğitim veri setinin de %10'u da doğrulama veri seti olarak ayrılmıştır. Toplam verilerin 6911 adeti eğitim, 768 adeti doğrulama ve 854 adeti de test amaçlı kullanılmıştır.

Tablo 6.7. DenseNet121 Veri Dağılımı

Veri Türü	Yüzde (%)
Eğitim	81
Validasyon	9
Test	10

Tablo 6.8.'de görüldüğü üzere, DenseNet121 modeli 100 döngü (epoch) boyunca eğitilmiştir; bu uzun eğitim süresi, modelin derin katman bağlantılarını yeterince keşfetmesine olanak tanır. Her adımda 32 örneklilik yığın (batch size) kullanılması, hem bellek verimliliğini hem de hesaplama hızını dengeler. Ağırlıklar, 0.0001'lik küçük bir öğrenme oranıyla (learning rate) güncellenerek, eğitim sırasında ani sıçramalar yerine daha kararlı bir iyileşme eğrisi sağlanmıştır. Aşırı öğrenmeyi önlemek amacıyla dropout oranı 0.5 olarak belirlenmiş; bu, tam bağlantılı katmandaki nöronların yarısının her iterasyonda rastgele devre dışı bırakılması anlamına gelir. Sınıflandırma kararı için kullanılan 0.51'lik eşik değeri, pozitif sınıfı (örneğin “maymun çiçeği”) belirlerken yanlış pozitifleri azaltmaya yönelik biraz daha temkinli bir yaklaşımdır. Son katmandaki 256 nöronluk yoğun (dense) yapı ise, modelin karmaşık görsel özellikleri ayırt edebilmesi için yeterli temsil kapasitesi sunmaktadır.

Tablo 6.8. DenseNet121 Hiperparametre Değerleri


Döngü	Yığın Boyutu	Öğrenme Oranı	Düşürme (Dropout)	Eşik Değeri	Nöron Sayısı
100	32	0.0001	0.5	0.51	256

Tablo 6.9’da DenseNet121 modelinin eğitim sonrası 854 örnekten oluşan test veri seti üzerindeki performans değerlendirmesi sunulmuştur. Model, sınıf 0 (maymun çiçeği olmayan) için %96.15 kesinlik (precision) ve %97.94 duyarlılık (recall) ile yüksek doğrulukta tahminlerde bulunmuş; sınıf 1 (maymun çiçeği) için ise %97.22 kesinlik ve %94.85 duyarlılık göstererek pozitif sınıfa karşı güçlü bir hassasiyet ortaya koymuştur. Bu performans, modelin iki sınıf arasında dengeli bir ayırım yapabildiğini göstermektedir. Makro ortalama değerler (her sınıfın eşit ağırlıkla değerlendirildiği durumda), %96.53 F1 skoru ile modelin genel olarak yüksek sınıflandırma başarısı sunduğunu ortaya koyarken; ağırlıklı ortalamalar (veri setindeki sınıf dağılımını dikkate alan ölçüm) üzerinden elde edilen %96.60 F1 skoru ise, modelin özellikle gerçek veri dağılımına duyarlı şekilde çalıştığını göstermektedir. Modelin genel doğruluk (accuracy) oranı %96.60 olarak hesaplanmıştır ve modelin doğru pozitif ve doğru negatif örnekleminin oldukça başarılı olduğunu göstermektedir. ROC eğrisi üzerinden Youden’s J istatistiği yöntemiyle belirlenen 0.5110 eşik değeri ile, DenseNet121’in hem doğru pozitif oranını yüksek tutmak hem de gereksiz yanlış pozitifleri minimumda tutmak üzere istatistiksel olarak optimize edilmiş bir yaklaşım olduğu söylenebilir. Test verisi üzerindeki kayıp (loss) değeri 0.1304 ile oldukça düşük bir seviyede kalmış, bu da modelin tahmin çıktıları ile gerçek etiketler arasında güçlü bir örtüşme sağladığını ve aşırı öğrenme (overfitting) göstermediğini ortaya koymaktadır. Model boyutu 31.25 MB olan DenseNet121, bu test işlemlerini NVIDIA Tesla T4 GPU üzerinde gerçekleştirmiştir. Donanım özellikleri arasında 16 GB RAM, GDDR6 bellek teknolojisi, 2560 CUDA çekirdeği ve 320 GBps bant genişliği yer almakta olup, bu altyapı modelin eğitim ve test süreçlerinde yüksek işlem verimliliği sağlamıştır. Sonuç olarak, DenseNet121 modeli, yüksek doğruluk, dengeli sınıf tahmini ve düşük kayıp oranıyla, özellikle tıbbi görüntü sınıflandırma uygulamalarında güvenle kullanılacak güçlü bir model olduğunu kanıtlamaktadır.

Tablo 6.9. DenseNet121 Sınıflandırıcı Performans Çıktıları

Sınıf	Kesinlik	Duyarlılık	F1 Skoru	Veri Sayısı
0	0.9615	0.9794	0.9704	485
1	0.9722	0.9485	0.9602	369
Makro Ortalama	0.9669	0.9639	0.9653	854
Ağırlıklı Ortalama	0.9662	0.9660	0.9660	854
Genel Model Doğruluğu	0.9660 - %96.60			
Genel Model Kesinliği	0.9662			
Genel Model Duyarlılığı	0.9660			
Genel Model F1 Skoru	0.9660			
Eşik Değeri	0.5110			
Kayıp Değeri	0.1304			
Model Boyutu	31.25 MB			
Eğitim Süresi	1 saat, 51 dakika, 36 saniye			
Donanım Özellikleri	NVIDIA Tesla T4 GPU 16 GB RAM GDDR6 SDRAM Technology 2560 CUDA Cores 320 GBps Bandwith			

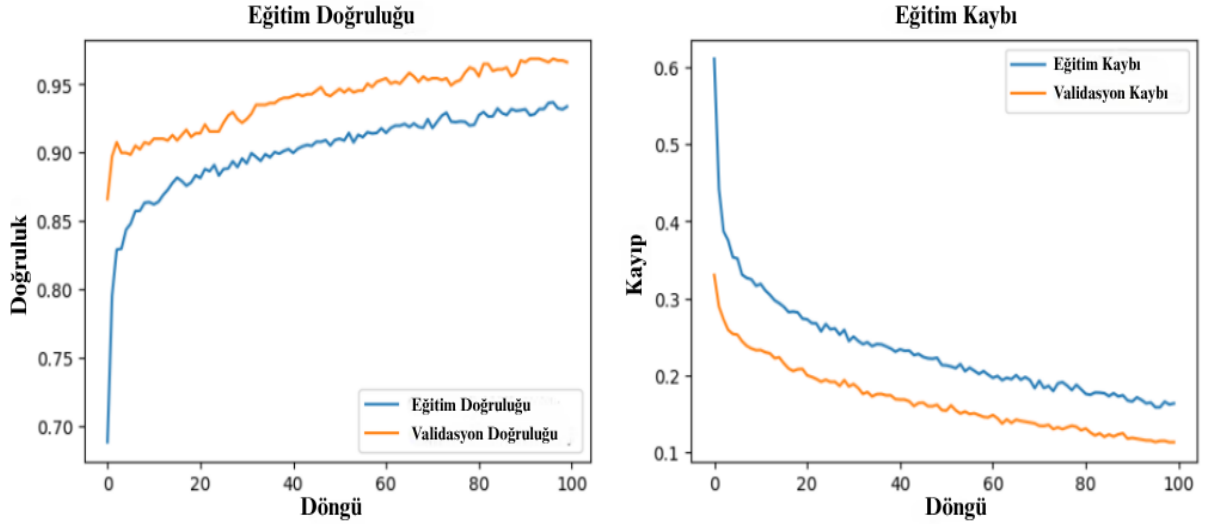
DenseNet121 modelinin test verisi üzerindeki karışıklık matrisi (confusion matrix) Şekil 6.10'da gösterilmiştir. Toplamda 854 adet veriden oluşan örneklem içerisinde 474 görüntü, hem gerçekte sınıf "0" olup hem de model tarafından doğru şekilde sınıf "0" olarak tahmin edilmiştir. 11 görüntü gerçekte sınıf "0" olmasına rağmen model tarafından yanlışlıkla sınıf "1" olarak sınıflandırılmıştır. Toplam 18 görüntü ise gerçekte sınıf "1" olmasına rağmen model tarafından hatalı şekilde sınıf "0" olarak tahmin edilmiştir. Öte yandan, 351 görüntü, hem gerçekte sınıf "1" olup hem de doğru şekilde model tarafından sınıf "1" olarak sınıflandırılmıştır. Bu doğrultuda, doğru negatif (true negative) örnek sayısı 474, yanlış pozitif (false positive) sayısı 11, yanlış negatif (false negative) sayısı 18 ve doğru pozitif (true positive) örnek sayısı 351'dir. Yanlış pozitif oranı %2.27, yanlış negatif oranı da %4.88'dir. Bu sonuçlar, modelin hem negatif hem de pozitif sınıfları yüksek bir doğrulukla ayırt edebildiğini göstermektedir.



Şekil 6.10. DenseNet121 Karışıklık Matrisi

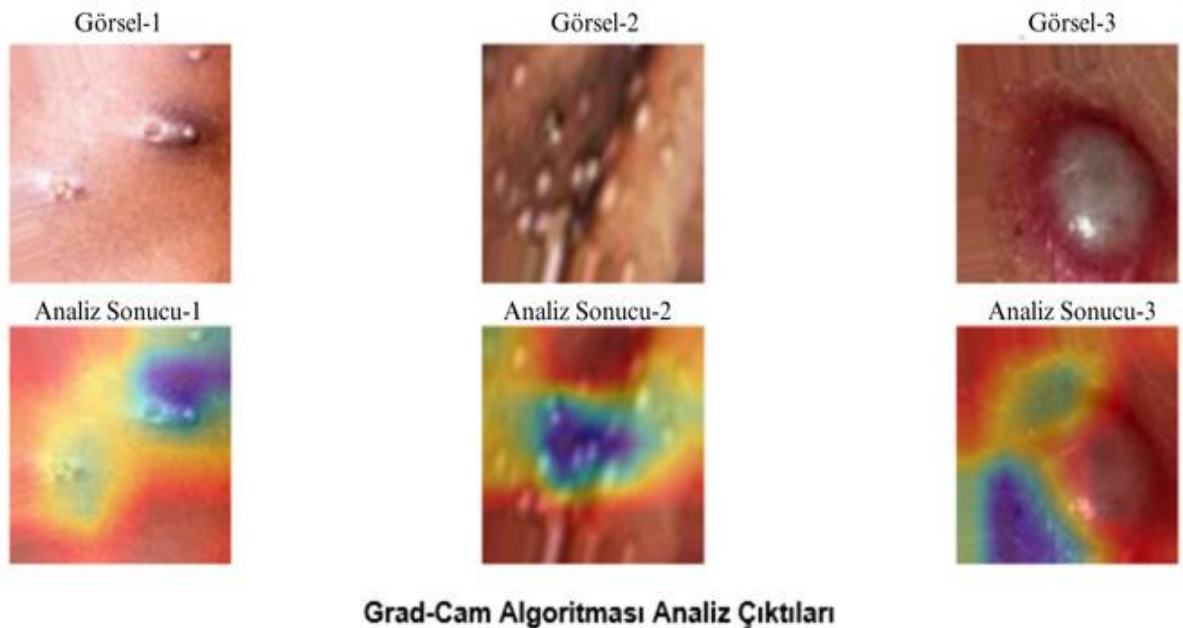
Şekil 6.11.'de görüldüğü gibi, döngü sayısı arttıkça modelin doğrulama görselleri üzerindeki tahmin doğruluğu yükselmekte ve kayıp fonksiyonu zamanla en düşük değere yakınsamaktadır. Bu durum, geri yayılım (backward propogation) sırasında ağırlık ve

önyargı (bias) katsayılarının güncellenmesiyle modelin giderek daha doğru tahminler yapabildiğini göstermektedir. Eğitim ve doğrulama doğruluk ve kayıp grafiklerinin benzer davranış göstermiştir.



Şekil 6.11. DenseNet121 Doğruluk ve Kayıp Grafikleri

Şekil 6.12.'de Gradyan Ağırlıklı Sınıf Aktivasyon Haritalaması (Grad-CAM) ile orijinal görüntülerde lezyonun yer aldığı kısım, Grad-CAM çıktılarında da yoğun renkli (sıcak) bölgelerle vurgulanmıştır. Bu, modelin gerçekten hastalıklı bölgeye odaklandığını, rastgele arka plana değil lezyonun karakteristik özelliklerine baktığını göstermektedir.



Grad-Cam Algoritması Analiz Çıktıları

Şekil 6.12. DenseNet121 Grad-CAM Analizi

6.4. DenseNet169 Modeli Deneysel Çıktılar & Analiz Sonuçları

Bu çalışmada DenseNet121, DenseNet169 ve DenseNet201 mimarileri transfer öğrenme yaklaşımıyla kullanılmıştır. Toplam veritabanının, %90'ı eğitim, %10'u test seti olarak ayrıldıktan sonra eğitim veri setinin de %10'u da doğrulama veri seti olarak ayrılmıştır. Toplam verilerin 6911 adeti eğitim, 768 adeti doğrulama ve 854 adeti de test amaçlı kullanılmıştır.

Tablo 6.10. DenseNet169 Veri Dağılımı

Veri Türü	Yüzde (%)
Eğitim	81
Validasyon	9
Test	10

Tablo 6.11.'de görüldüğü üzere, DenseNet121 modeli 100 döngü (epoch) boyunca eğitilmiştir; bu uzun eğitim süresi, modelin derin katman bağlantılarını yeterince keşfetmesine olanak tanımaktadır. Her adımda 32 örneklilik yığın (batch size) kullanılması, hem bellek verimliliğini hem de hesaplama hızını dengeler. Ağırlıklar, 0.0001'lik küçük bir öğrenme oranıyla (learning rate) güncellenerek, eğitim sırasında ani sıçramalar yerine daha kararlı bir iyileşme eğrisi sağlanmıştır. Aşırı öğrenmeyi önlemek amacıyla dropout oranı 0.5 olarak belirlenmiş; bu, tam bağlantılı katmandaki nöronların yarısının her iterasyonda rastgele devre dışı bırakılması anlamına gelir. Sınıflandırma kararı için kullanılan 0.36'lik eşik değeri, pozitif sınıfı (örneğin “maymun çiçeği”) belirlerken yanlış pozitifleri azaltmaya yönelik biraz daha temkinli bir yaklaşımdır. Son katmandaki 256 nöronluk yoğun (dense) yapı ise, modelin karmaşık görsel özellikleri ayırt edebilmesi için yeterli temsil kapasitesi sunmaktadır.

Tablo 6.11. Densenet169 Hiperparametre Değerleri


Döngü	Yığın Boyutu	Öğrenme Oranı	Düşürme (Dropout)	Eşik Değeri	Nöron Sayısı
100	32	0.0001	0.5	0.36	256

Tablo 6.12.'de DenseNet169 modelinin eğitim sonrası 854 örnekten oluşan test veri seti üzerindeki performans değerlendirmesi sunulmuştur. Model, sınıf 0 (maymun çiçeği olmayan) için %99.16 kesinlik (precision) ve %98.14 duyarlılık (recall) ile yüksek doğrulukta tahminlerde bulunmuş; sınıf 1 (maymun çiçeği) için ise %97.59 kesinlik ve %98.91 duyarlılık göstererek pozitif sınıfa karşı güçlü bir hassasiyet ortaya koymuştur. Bu performans, modelin iki sınıf arasında dengeli bir ayırım yapabildiğini göstermektedir. Makro ortalama değerler (her sınıfın eşit ağırlıkla değerlendirildiği durumda), %98.45 F1 skoru ile modelin genel olarak yüksek sınıflandırma başarısı sunduğunu ortaya koyarken; ağırlıklı ortalamalar (veri setindeki sınıf dağılımını dikkate alan ölçüm) üzerinden elde edilen %98.48 F1 skoru ise, modelin özellikle gerçek veri dağılımına duyarlı şekilde çalıştığını göstermektedir. Modelin genel doğruluk (accuracy) oranı %98.48 olarak hesaplanmıştır ve modelin doğru pozitif ve doğru negatif örnekleminin oldukça başarılı olduğunu göstermektedir. ROC eğrisi üzerinden Youden's J istatistiği yöntemiyle belirlenen 0.3632 eşik değeri ile, DenseNet169'un hem doğru pozitif oranını yüksek tutmak hem de gereksiz yanlış pozitifleri minimumda tutmak üzere istatistiksel olarak optimize edilmiş bir yaklaşım olduğu söylenebilir. Test verisi üzerindeki kayıp (loss) değeri 0.0750 ile oldukça düşük bir seviyede kalmış, bu da modelin tahmin çıktıları ile gerçek etiketler arasında güçlü bir örtüşme sağladığını ve aşırı öğrenme (overfitting) göstermediğini ortaya koymaktadır. Model boyutu 54.87 MB olan DenseNet169, bu test işlemlerini NVIDIA Tesla T4 GPU üzerinde gerçekleştirmiştir. Donanım özellikleri arasında 16 GB RAM, GDDR6 bellek teknolojisi, 2560 CUDA çekirdeği ve 320 GBps bant genişliği yer almakta olup, bu altyapı modelin eğitim ve test süreçlerinde yüksek işlem verimliliği sağlamıştır. Sonuç olarak, DenseNet169 modeli, yüksek doğruluk, dengeli sınıf tahmini ve düşük kayıp oranıyla, özellikle tıbbi görüntü sınıflandırma uygulamalarında güvenle kullanılacak güçlü bir model olduğunu kanıtlamaktadır.

Tablo 6.12. DenseNet169 Sınıflandırıcı Performans Çıktıları

Sınıf	Kesinlik	Duyarlılık	F1 Skoru	Veri Sayısı
0	0.9916	0.9814	0.9865	485
1	0.9759	0.9891	0.9825	369
Makro Ortalama	0.9838	0.9814	0.9845	854
Ağırlıklı Ortalama	0.9849	0.9848	0.9848	854
Genel Model Doğruluğu	0.9848 - %98.48			
Genel Model Kesinliği	0.9849			
Genel Model Duyarlılığı	0.9848			
Genel Model F1 Skoru	0.9848			
Eşik Değeri	0.3632			
Kayıp Değeri	0.075			
Model Boyutu	54.87 MB			
Eğitim Süresi	3 saat 20 dakika 20 saniye			
Donanım Özellikleri	NVIDIA Tesla T4 GPU 16 GB RAM GDDR6 SDRAM Technology 2560 CUDA Cores 320 GBps Bandwith			


DenseNet169 modelinin test verisi üzerindeki karışıklık matrisi (confusion matrix) Şekil 6.13’de gösterilmiştir. Toplamda 854 adet veriden oluşan örneklem içerisinde 482 görüntü, hem gerçekte sınıf “0” olup hem de model tarafından doğru şekilde sınıf “0” olarak tahmin edilmiştir. 3 görüntü gerçekte sınıf “0” olmasına rağmen model tarafından yanlışlıkla sınıf “1” olarak sınıflandırılmıştır. Toplam 10 görüntü ise gerçekte sınıf “1” olmasına rağmen model tarafından hatalı şekilde sınıf “0” olarak tahmin edilmiştir. Öte yandan, 359 görüntü, hem gerçekte sınıf “1” olup hem de doğru şekilde model tarafından sınıf “1” olarak sınıflandırılmıştır. Bu doğrultuda, doğru negatif (true negative) örnek sayısı 482, yanlış pozitif (false positive) sayısı 3, yanlış negatif (false negative) sayısı 10 ve doğru pozitif (true positive) örnek sayısı 359’dur. Yanlış pozitif oranı %0.62, yanlış negatif oranı da %2.71’dir. Bu sonuçlar, modelin hem negatif hem de pozitif sınıfları yüksek bir doğrulukla ayırt edebildiğini göstermektedir.



Şekil 6.13. DenseNet169 Karışıklık Matrisi

Şekil 6.14.’de çalışmada kullanılan önceden eğitilmiş DenseNet169 modelinin doğruluğunun döngü boyunca 1’e yakınsadığı, kayıp grafiğinin de 0’a yaklaştığı görülmektedir. Bu durum, modelin hem eğitim hem de görmediği doğrulama verisi üzerinde sürekli olarak öğrenmeye devam ettiği ve yüksek genelleme kabiliyeti kazandığını göstermektedir. Doğrulama kaybının da eğitim kaybının çok altında veya üstünde seyretmediğinin ve dolayısıyla model için aşırı öğrenme veya az öğrenme olmadığını ortaya

koymaktadır. Modelin döngü boyunca kayıp değerinin azalması ve dip noktaya yaklaşması artık modelin öğrendiğini, parametre değerlerinin en güncel ve etkili seviyeye geldiğini, modelin gerçek ve tahmin ettiği etiketlerin örtüştüğü anlamına gelmektedir. Eğitim ve doğrulama performanslarının güçlü ve paralel seyretmesi de modelin çok güçlü tahminleme yeteneğine sahip olduğunu vurgulamaktadır.



Şekil 6.14. DenseNet169 Doğruluk ve Kayıp Grafikleri

Şekil 6.15.'de Gradyan Ağırlıklı Sınıf Aktivasyon Haritalaması (Grad-CAM) ile orijinal görüntülerde lezyonun yer aldığı kısım, Grad-CAM çıktılarında da yoğun renkli (sıcak) bölgelerle vurgulanmıştır. Bu, modelin gerçekten hastalıklı bölgeye odaklandığını, rastgele arka plana değil lezyonun karakteristik özelliklerine baktığını göstermektedir.



Şekil 6.15. DenseNet169 Grad-CAM Analizi

6.5. DenseNet201 Modeli Deneysel Çıktılar & Analiz Sonuçları

DenseNet201, DenseNet121 ve DenseNet169 mimarilerine göre daha derin bir sinir ağıdır. Bu çalışmada DenseNet201 modeli için transfer öğrenme yaklaşımı ile kullanılmıştır. Toplam veri setinin %90'ı eğitim, %10'u test veritabanı olarak ayrıldıktan sonra eğitim veri setinin de %10'u da doğrulama veri seti olarak ayrılmıştır. Toplam verilerin 6911 adeti eğitim, 768 adeti doğrulama ve 854 adeti de test amaçlı kullanılmıştır.

Tablo 6.13. DenseNet201 Veri Dağılımı

Veri Türü	Yüzde (%)
Eğitim	81
Validasyon	9
Test	10

Modelin eğitimi sırasında kullanılan hiperparametre değerleri aşağıdaki tabloda gösterilmektedir. Çalışma boyunca modelin tüm eğitim verisi üzerinde 100 kere eğitilmiştir. Her seferde eğitime alınan örnek sayısı 32 olarak belirlenmiştir. Ağırlıkların güncellenme hızı 0.0001'dir. Aşırı öğrenmeyi önlemek için nöronların rastgele devre dışı bırakılma oranı 0.5 olarak belirlenmiştir. Modelin hangi olasılıkla bir sınıfa karar verdiğini belirleyen eşik 0.56 olarak algoritma analizi sonucunda optimal belirlenmiştir. Tam bağlantılı katmandaki nöron sayısı ise 256'dır.

Tablo 6.14. DenseNet201 Hiperparametre Değerleri

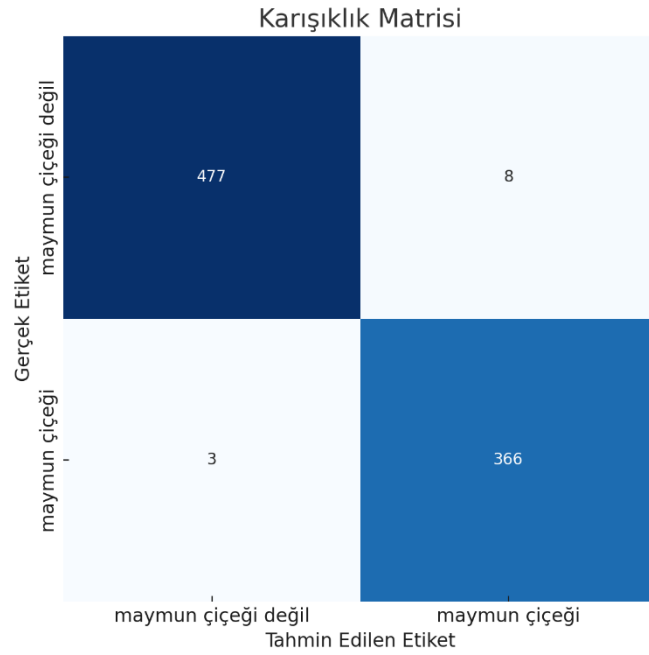
Döngü	Yığın Boyutu	Öğrenme Oranı	Düşürme (Dropout)	Eşik Değeri	Nöron Sayısı
100	32	0.0001	0.5	0.56	256

Tablo 6.15’de DenseNet201 modelinin eğitim sonrası 854 örnekten oluşan test veri seti üzerindeki performans değerlendirmesi sunulmuştur. Model, sınıf 0 (maymun çiçeği olmayan) için %99.17 kesinlik (precision) ve %98.97 duyarlılık (recall) ile yüksek doğrulukta tahminlerde bulunmuş; sınıf 1 (maymun çiçeği) için ise %98.65 kesinlik ve %98.92 duyarlılık göstererek pozitif sınıfa karşı güçlü bir hassasiyet ortaya koymuştur. Bu performans, modelin iki sınıf arasında dengeli bir ayırım yapabildiğini göstermektedir. Makro ortalama değerler (her sınıfın eşit ağırlıkla değerlendirildiği durumda), %98.93 F1 skoru ile modelin genel olarak yüksek sınıflandırma başarısı sunduğunu ortaya koyarken; ağırlıklı ortalamalar (veri setindeki sınıf dağılımını dikkate alan ölçüm) üzerinden elde edilen %98.95 F1 skoru ise, modelin özellikle gerçek veri dağılımına duyarlı şekilde çalıştığını göstermektedir. Modelin genel doğruluk (accuracy) oranı %98.95 olarak hesaplanmıştır ve modelin doğru pozitif ve doğru negatif örnekleminin oldukça başarılı olduğunu göstermektedir. ROC eğrisi üzerinden Youden’s J istatistiği yöntemiyle belirlenen 0.5644 eşik değeri ile, DenseNet169’un hem doğru pozitif oranını yüksek tutmak hem de gereksiz yanlış pozitifleri minimumda tutmak üzere istatistiksel olarak optimize edilmiş bir yaklaşım olduğu söylenebilir. Test verisi üzerindeki kayıp (loss) değeri 0.0536 ile oldukça düşük bir seviyede kalmış, bu da modelin tahmin çıktıları ile gerçek etiketler arasında güçlü bir örtüşme sağladığını ve aşırı öğrenme (overfitting) göstermediğini ortaya koymaktadır. Model boyutu 77.83 MB olan DenseNet201, bu test işlemlerini NVIDIA Tesla T4 GPU üzerinde gerçekleştirmiştir. Donanım özellikleri arasında 16 GB RAM, GDDR6 bellek teknolojisi, 2560 CUDA çekirdeği ve 320 GBps bant genişliği yer almakta olup, bu altyapı modelin eğitim ve test süreçlerinde yüksek işlem verimliliği sağlamıştır. Sonuç olarak, DenseNet201 modeli, yüksek doğruluk, dengeli sınıf tahmini ve düşük kayıp oranıyla, özellikle tıbbi görüntü sınıflandırma uygulamalarında güvenle kullanılabilir bir güçlü bir model olduğunu kanıtlamaktadır.

Tablo 6.15. DenseNet201 Sınıflandırıcı Performans Çıktıları

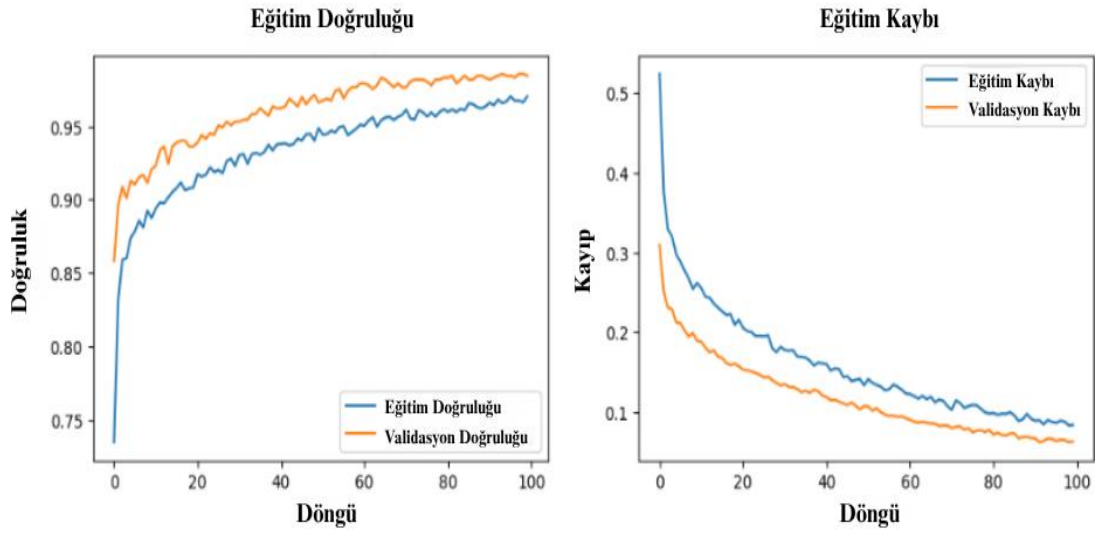
Sınıf	Kesinlik	Duyarlılık	F1 Skoru	Veri Sayısı
0	0.9917	0.9897	0.9907	485
1	0.9865	0.9892	0.9878	369
Makro Ortalama	0.9891	0.9894	0.9893	854
Ağırlıklı Ortalama	0.9895	0.9895	0.9895	854
Genel Model Doğruluğu	0.9895- %98.95			
Genel Model Kesinliği	0.9895			
Genel Model Duyarlılığı	0.9895			
Genel Model F1 Skoru	0.9895			
Eşik Değeri	0.5644			
Kayıp Değeri	0.0536			
Model Boyutu	77.83 MB			
Eğitim Süresi	2 saat, 23 dakika, 37 saniye			
Donanım Özellikleri	NVIDIA Tesla T4 GPU 16 GB RAM GDDR6 SDRAM Technology 2560 CUDA Cores 320 GBps Bandwith			

DenseNet201 modelinin test verisi üzerindeki karışıklık matrisi (confusion matrix) Şekil 6.16.'da gösterilmiştir. Toplamda 854 adet veriden oluşan örneklem içerisinde 477 görüntü, hem gerçekte sınıf “0” olup hem de model tarafından doğru şekilde sınıf “0” olarak tahmin edilmiştir. 8 görüntü gerçekte sınıf “0” olmasına rağmen model tarafından yanlışlıkla sınıf “1” olarak sınıflandırılmıştır. Toplam 3 görüntü ise gerçekte sınıf “1” olmasına rağmen model tarafından hatalı şekilde sınıf “0” olarak tahmin edilmiştir. Öte yandan, 366 görüntü, hem gerçekte sınıf “1” olup hem de doğru şekilde model tarafından sınıf “1” olarak sınıflandırılmıştır. Bu doğrultuda, doğru negatif (true negative) örnek sayısı 477, yanlış pozitif (false positive) sayısı 8, yanlış negatif (false negative) sayısı 3 ve doğru pozitif (true positive) örnek sayısı 366’dur. Yanlış pozitif oranı %1.65, yanlış negatif oranı da %0.81’dir. Bu sonuçlar, modelin hem negatif hem de pozitif sınıfları yüksek bir doğrulukla ayırt edebildiğini göstermektedir.




Şekil 6.16 DenseNet201 Karışıklık Matrisi

Şekil 6.17.'de modelin görülmemiş veriyi (validasyon), eğitime göre daha iyi genellediğini, eğitime yönelik öğrenmenin daha yavaş ama istikrarlı gerçekleştiğini göstermektedir. Kayıpların eğitim ve doğrulamada birbirine yakın olması, modelin aşırı öğrenme (overfitting) yapmadığını, hem eğitim hem de doğrulama verisini tutarlı biçimde öğrendiğini işaret etmektedir. Model, ilk birkaç döngüde hızla öğrenip kaybı düşürürken doğrulama doğruluğunu %95 üzerine kadar çıkarmakta; eğitim doğruluğuysa daha yavaş – fakat istikrarlı – bir artış göstererek %90 seviyelerinde dengelenmektedir. Döngü boyunca model doğruluğunun artması ve özellikle kayıp değerinin 0 hizasına oldukça yakınsaması modelin iyi öğrendiğini ve gerçek etiketler ile tahmin edilen etiketlerin örtüştüğünü göstermektedir.



Şekil 6.17. DenseNet201 Doğruluk Kayıp Grafikleri

Şekil 6.18’de Gradyan Ağırlıklı Sınıf Aktivasyon Haritalaması (Grad-CAM) ile orijinal görüntülerde lezyonun yer aldığı kısım, Grad-CAM çıktılarında da yoğun renkli (sıcak) bölgelerle vurgulanmıştır. Bu, modelin gerçekten hastalıklı bölgeye odaklandığını, rastgele arka plana değil lezyonun karakteristik özelliklerine baktığını göstermektedir.



Şekil 6.18. DenseNet201 Grad-CAM Analizi

6.6. Inceptionv3 Modeli Deneysel Çıktılar & Analiz Sonuçları

Bu çalışmada Inceptionv3 modeli transfer öğrenme yaklaşımı ile kullanılmıştır. Toplam veritabanınının %90’ı eğitim, %10’u test seti olarak ayrıldıktan sonra eğitim veri setinin de %10’u da doğrulama veri seti olarak ayrılmıştır. Toplam verilerin 6911 adeti eğitim, 768 adeti doğrulama ve 854 adeti de test amaçlı kullanılmıştır.

Tablo 6.16. Inceptionv3 Veri Dağılımı

Veri Türü	Yüzde (%)
Eğitim	81
Validasyon	9
Test	10

Modelin eğitimi sırasında kullanılan hiperparametre değerleri aşağıdaki şekilde gösterilmektedir. Çalışma boyunca modelin tüm eğitim verisi üzerinde 100 kere eğitilmiştir. Her seferde eğitime alınan örnek sayısı 32 olarak belirlenmiştir. Ağırlıkların güncellenme hızı 0.0001'dir. Aşırı öğrenmeyi önlemek için nöronların rastgele devre dışı bırakılma oranı 0.5 olarak belirlenmiştir. Modelin hangi olasılıkla bir sınıfa karar verdiğini belirleyen eşik 0.44 olarak algoritma analizi sonucunda optimal belirlenmiştir. Tam bağlantılı katmandaki nöron sayısı ise 256'dır.

Tablo 6.17. Inceptionv3 Hiperparametre Değerleri

Döngü	Yığın Boyutu	Öğrenme Oranı	Düşürme (Dropout)	Eşik Değeri	Nöron Sayısı
100	32	0.0001	0.5	0.44	256


Tablo 6.18'de Inceptionv3 modelinin eğitim sonrası 854 örnekten oluşan test veri seti üzerindeki performans değerlendirmesi sunulmuştur. Model, sınıf 0 (maymun çiçeği olmayan) için %98.53 kesinlik (precision) ve %96.49 duyarlılık (recall) ile yüksek doğrulukta tahminlerde bulunmuş; sınıf 1 (maymun çiçeği) için ise %95.51 kesinlik ve %98.10 duyarlılık göstererek pozitif sınıfa karşı güçlü bir hassasiyet ortaya koymuştur. Bu performans, modelin iki sınıf arasında dengeli bir ayırım yapabildiğini göstermektedir. Makro ortalama değerler (her sınıfın eşit ağırlıkla değerlendirildiği durumda), %97.15 F1 skoru ile modelin genel olarak yüksek sınıflandırma başarısı sunduğunu ortaya koyarken; ağırlıklı ortalamalar (veri setindeki sınıf dağılımını dikkate alan ölçüm) üzerinden elde edilen %97.19 F1 skoru ise, modelin özellikle gerçek veri dağılımına duyarlı şekilde çalıştığını göstermektedir. Modelin genel doğruluk (accuracy) oranı %97.19 olarak hesaplanmıştır ve modelin doğru pozitif ve doğru negatif örnekleminin oldukça başarılı olduğunu göstermektedir. ROC eğrisi üzerinden Youden's J istatistiği yöntemiyle belirlenen 0.4447 eşik değeri ile, DenseNet169'un hem doğru pozitif oranını yüksek tutmak hem de gereksiz yanlış pozitifleri minimumda tutmak üzere istatistiksel olarak optimize edilmiş bir yaklaşım olduğu söylenebilir. Test verisi üzerindeki kayıp (loss) değeri 0.0751 ile oldukça düşük bir seviyede kalmış, bu da modelin tahmin çıktıları ile gerçek etiketler arasında güçlü

bir örtüşme sağladığını ve aşırı öğrenme (overfitting) göstermediğini ortaya koymaktadır. Model boyutu 90.19 MB olan Inceptionv3, bu test işlemlerini NVIDIA Tesla T4 GPU üzerinde gerçekleştirmiştir. Donanım özellikleri arasında 16 GB RAM, GDDR6 bellek teknolojisi, 2560 CUDA çekirdeği ve 320 GBps bant genişliği yer almakta olup, bu altyapı modelin eğitim ve test süreçlerinde yüksek işlem verimliliği sağlamıştır. Sonuç olarak, Inceptionv3 modeli, yüksek doğruluk, dengeli sınıf tahmini ve düşük kayıp oranıyla, özellikle tıbbi görüntü sınıflandırma uygulamalarında güvenle kullanılacak güçlü bir model olduğunu kanıtlamaktadır.

Tablo 6.18. Inceptionv3 Sınıflandırıcı Performans Çıktıları

Sınıf	Kesinlik	Duyarlılık	F1 Skoru	Veri Sayısı
0	0.9853	0.9649	0.9750	485
1	0.9551	0.9810	0.9679	369
Makro Ortalama	0.9702	0.9730	0.9715	854
Ağırlıklı Ortalama	0.9722	0.9719	0.9719	854
Genel Model Doğruluğu	0.9719 - %97.19			
Genel Model Kesinliği	0.9722			
Genel Model Duyarlılığı	0.9719			
Genel Model F1 Skoru	0.9719			
Eşik Değeri	0.4447			
Kayıp Değeri	0.0751			
Model Boyutu	90.19 MB			
Eğitim Süresi	2 saat, 19 dakika, 34 saniye			
Donanım Özellikleri	NVIDIA Tesla T4 GPU 16 GB RAM GDDR6 SDRAM Technology 2560 CUDA Cores 320 GBps Bandwith			


Inceptionv3 modelinin test verisi üzerindeki karışıklık matrisi (confusion matrix) Şekil 6.19’da gösterilmiştir. Toplamda 854 adet veriden oluşan örneklem içerisinde 471 görüntü, hem gerçekte sınıf “0” olup hem de model tarafından doğru şekilde sınıf “0” olarak tahmin edilmiştir. 14 görüntü gerçekte sınıf “0” olmasına rağmen model tarafından yanlışlıkla sınıf “1” olarak sınıflandırılmıştır. Toplam 10 görüntü ise gerçekte sınıf “1” olmasına rağmen model tarafından hatalı şekilde sınıf “0” olarak tahmin edilmiştir. Öte yandan, 359 görüntü, hem gerçekte sınıf “1” olup hem de doğru şekilde model tarafından sınıf “1” olarak sınıflandırılmıştır. Bu doğrultuda, doğru negatif (true negative) örnek sayısı 471, yanlış pozitif (false positive) sayısı 14, yanlış negatif (false negative) sayısı 10 ve doğru pozitif (true positive) örnek sayısı 359’dur. Yanlış pozitif oranı %2.89, yanlış negatif oranı da %2.71’dir. Bu sonuçlar, modelin hem negatif hem de pozitif sınıfları yüksek bir doğrulukla ayırt edebildiğini göstermektedir.



Şekil 6.19. Inceptionv3 Karışıklık Matrisi

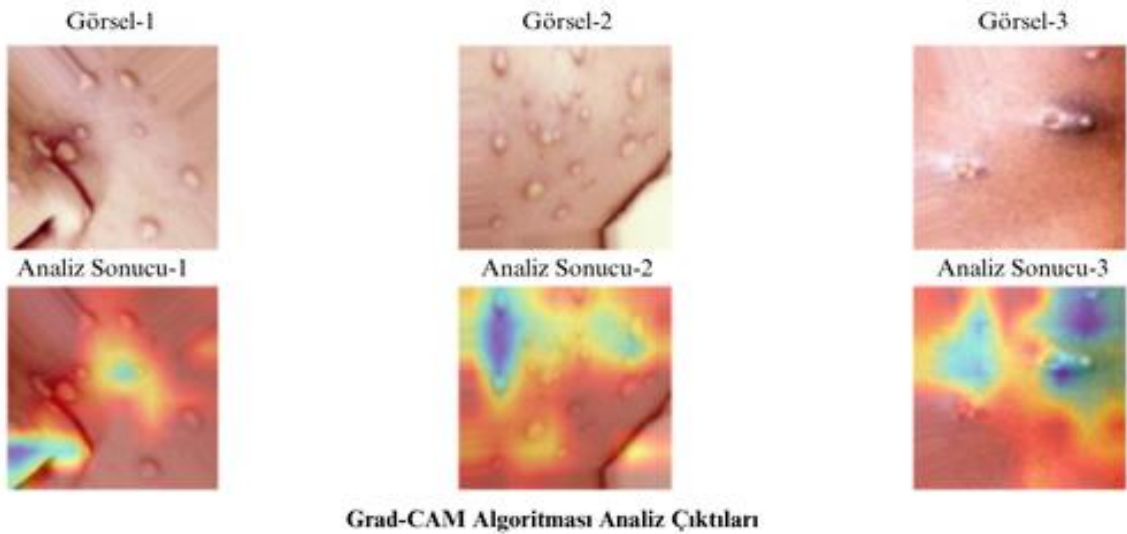
Şekil 6.20’deki grafikten modelin 100 döngü boyunca hem eğitim hem de doğrulama verisi üzerindeki başarı ve kayıp eğrilerinin yakından takip edildiği görülüyor. İlk birkaç döngüde eğitim doğruluğu hızla %70’in üzerine çıkarken, doğrulama doğruluğu da %80–%85 bandında başlayıp benzer bir hızla yükselerek 100. döngüde %96’ya yakın bir değere ulaşıyor. Aynı şekilde, eğitim kaybı başlangıçtaki ~0,75’ten sistematik bir düşüşle 0,1’in altına inerken, doğrulama kaybı da 0,45’ten 0,08–0,10 bandına geriliyor. Eğitim ve

doğrulama metriklerinin birbirine paralel seyretmesi, modelin aşırı öğrenme (overfitting) yapmadığını ve genelleme kabiliyetinin güçlü olduğunu, dolayısıyla hem öğrendiği hem de görmediği veride tutarlı performans gösterdiğini işaret ediyor.



Şekil 6.20. Inceptionv3 Doğruluk Kayıp Grafikleri

Şekil 6.21.'de Gradyan Ağırlıklı Sınıf Aktivasyon Haritalaması (Grad-CAM) ile orijinal görüntülerde lezyonun yer aldığı kısım, Grad-CAM çıktılarında da yoğun renkli (sıcak) bölgelerle vurgulanmıştır. Bu, modelin gerçekten hastalıklı bölgeye odaklandığını, rastgele arka plana değil lezyonun karakteristik özelliklerine baktığını göstermektedir.



Grad-CAM Algoritması Analiz Çıktıları

Şekil 6.21. Inceptionv3 Grad-CAM Analizi

6.7. Xception Modeli Deneysel Çıktılar & Analiz Sonuçları

Bu çalışmada Xception modeli, transfer öğrenme yaklaşımı ile kullanılmıştır. Toplam veritabanının %90'ı eğitim, %10'u test seti olarak ayrıldıktan sonra eğitim veri setinin de %10'u da doğrulama veri seti olarak ayrılmıştır. Toplam verilerin 6911 adeti eğitim, 768 adeti doğrulama ve 854 adeti de test amaçlı kullanılmıştır.

Tablo 6.19. Xception Veri Dağılımı

Veri Türü	Yüzde (%)
Eğitim	81
Validasyon	9
Test	10

Modelin eğitimi sırasında kullanılan hiperparametre değerleri aşağıdaki şekilde gösterilmektedir. Çalışma boyunca modelin tüm eğitim verisi üzerinde 100 kere eğitilmiştir. Her seferde eğitime alınan örnek sayısı 32 olarak belirlenmiştir. Ağırlıkların güncellenme hızı 0.0001'dir. Aşırı öğrenmeyi önlemek için nöronların rastgele devre dışı bırakılma oranı 0.5 olarak belirlenmiştir. Modelin hangi olasılıkla bir sınıfa karar verdiğini belirleyen eşik 0.47 olarak algoritma analizi sonucunda optimal belirlenmiştir. Tam bağlantılı katmandaki nöron sayısı ise 256'dır.

Tablo 6.20. Xception Hiperparametre Değerleri


Döngü	Yığın Boyutu	Öğrenme Oranı	Düşürme (Dropout)	Eşik Değeri	Nöron Sayısı
100	32	0.0001	0.5	0.47	256

Tablo 6.21’de Xception modelinin eğitim sonrası 854 örnekten oluşan test veri seti üzerindeki performans değerlendirmesi sunulmuştur. Model, sınıf 0 (maymun çiçeği olmayan) için %98.55 kesinlik (precision) ve %98.35 duyarlılık (recall) ile yüksek doğrulukta tahminlerde bulunmuş; sınıf 1 (maymun çiçeği) için ise %97.84 kesinlik ve %98.10 duyarlılık göstererek pozitif sınıfa karşı güçlü bir hassasiyet ortaya koymuştur. Bu performans, modelin iki sınıf arasında dengeli bir ayırım yapabildiğini göstermektedir. Makro ortalama değerler (her sınıfın eşit ağırlıkla değerlendirildiği durumda), %98.21 F1 skoru ile modelin genel olarak yüksek sınıflandırma başarısı sunduğunu ortaya koyarken; ağırlıklı ortalamalar (veri setindeki sınıf dağılımını dikkate alan ölçüm) üzerinden elde edilen %98.24 F1 skoru ise, modelin özellikle gerçek veri dağılımına duyarlı şekilde çalıştığını göstermektedir. Modelin genel doğruluk (accuracy) oranı %98.24 olarak hesaplanmıştır ve modelin doğru pozitif ve doğru negatif örnekleminin oldukça başarılı olduğunu göstermektedir. ROC eğrisi üzerinden Youden’s J istatistiği yöntemiyle belirlenen 0.4690 eşik değeri ile, Xception’ın hem doğru pozitif oranını yüksek tutmak hem de gereksiz yanlış pozitifleri minimumda tutmak üzere istatistiksel olarak optimize edilmiş bir yaklaşım olduğu söylenebilir. Test verisi üzerindeki kayıp (loss) değeri 0.0655 ile oldukça düşük bir seviyede kalmış, bu da modelin tahmin çıktıları ile gerçek etiketler arasında güçlü bir örtüşme sağladığını ve aşırı öğrenme (overfitting) göstermediğini ortaya koymaktadır. Model boyutu 90.19 MB olan Inceptionv3, bu test işlemlerini NVIDIA Tesla T4 GPU üzerinde gerçekleştirmiştir. Donanım özellikleri arasında 16 GB RAM, GDDR6 bellek teknolojisi, 2560 CUDA çekirdeği ve 320 GBps bant genişliği yer almakta olup, bu altyapı modelin eğitim ve test süreçlerinde yüksek işlem verimliliği sağlamıştır. Sonuç olarak, Xception modeli, yüksek doğruluk, dengeli sınıf tahmini ve düşük kayıp oranıyla, özellikle tıbbi görüntü sınıflandırma uygulamalarında güvenle kullanılacak güçlü bir model olduğunu kanıtlamaktadır.

Tablo 6.21. Xception Sınıflandırıcı Performans Çıktıları

Sınıf	Kesinlik	Duyarlılık	F1 Skoru	Veri Sayısı
0	0.9855	0.9835	0.9845	485
1	0.9784	0.9810	0.9797	369
Makro Ortalama	0.9820	0.9823	0.9821	854
Ağırlıklı Ortalama	0.9824	0.9824	0.9824	854
Genel Model Doğruluğu	0.9824 - %98.24			
Genel Model Kesinliği	0.9824			
Genel Model Duyarlılığı	0.9824			
Genel Model F1 Skoru	0.9824			
Eşik Değeri	0.4690			
Kayıp Değeri	0.0655			
Model Boyutu	86.02 MB			
Eğitim Süresi	1 saat, 55 dakika, 21 saniye			
Donanım Özellikleri	NVIDIA Tesla T4 GPU 16 GB RAM GDDR6 SDRAM Technology 2560 CUDA Cores 320 GBps Bandwith			

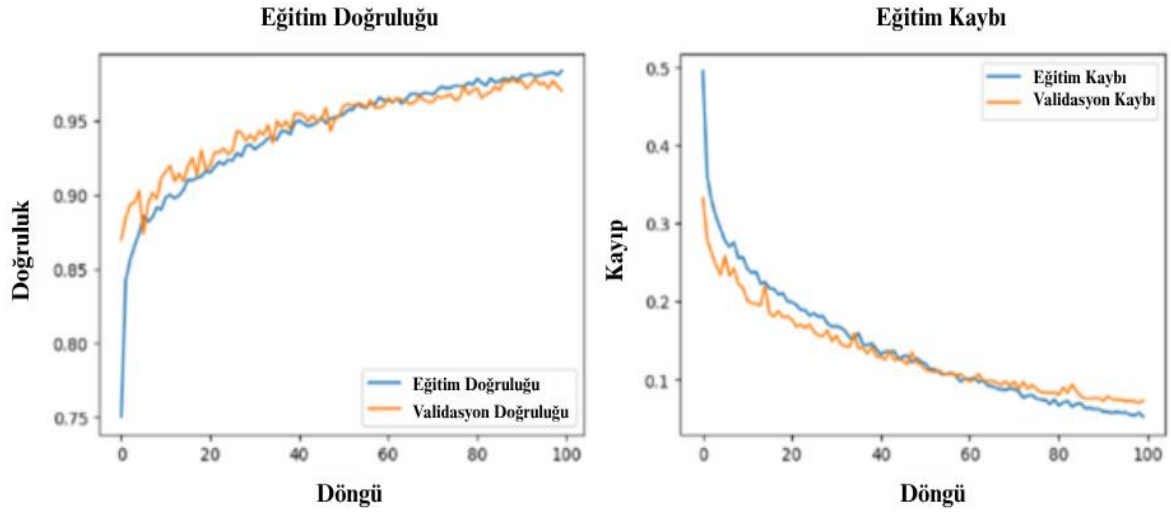
Xception modelinin test verisi üzerindeki karışıklık matrisi (confusion matrix) Şekil 6.22’de gösterilmiştir. Toplamda 854 adet veriden oluşan örneklem içerisinde 478 görüntü, hem gerçekte sınıf “0” olup hem de model tarafından doğru şekilde sınıf “0” olarak tahmin edilmiştir. 7 görüntü gerçekte sınıf “0” olmasına rağmen model tarafından yanlışlıkla sınıf “1” olarak sınıflandırılmıştır. Toplam 8 görüntü ise gerçekte sınıf “1” olmasına rağmen model tarafından hatalı şekilde sınıf “0” olarak tahmin edilmiştir. Öte yandan, 361 görüntü, hem gerçekte sınıf “1” olup hem de doğru şekilde model tarafından sınıf “1” olarak sınıflandırılmıştır. Bu doğrultuda, doğru negatif (true negative) örnek sayısı 478, yanlış pozitif (false positive) sayısı 7, yanlış negatif (false negative) sayısı 8 ve doğru pozitif (true positive) örnek sayısı 361’dir. Yanlış pozitif oranı %1.44, yanlış negatif oranı da %2.17’dir. Bu sonuçlar, modelin hem negatif hem de pozitif sınıfları yüksek bir doğrulukla ayırt edebildiğini göstermektedir.



Şekil 6.22. Xception Karışıklık Matrisi

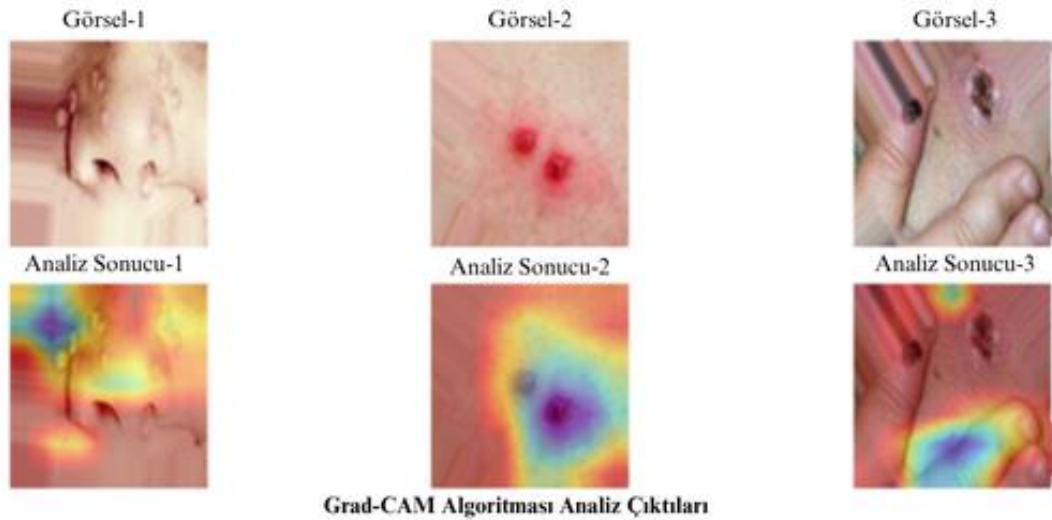
Şekil 6.23’de Xception doğruluk-kayıp grafiğinde modelin 100 döngü süresince gösterdiği performans izlenmiştir. Doğruluk-Döngü grafiğine göre, eğitim ve doğrulama doğrulukları zamanla artmış ve %95’in üzerine çıkarak oldukça yüksek bir seviyeye ulaşmıştır. Doğrulama doğruluğunun eğitim doğruluğuna yakın seyretmesi, modelin overfitting (aşırı öğrenme) yapmadığını ve genelleme yeteneğinin güçlü olduğunu

göstermektedir. Sağ taraftaki kayıp (loss) grafiğinde ise hem eğitim hem de doğrulama kayıpları sürekli olarak azalmış ve birbirine yakın değerlerde seyretmiştir. Bu durum, modelin hem eğitim hem de doğrulama verileri üzerinde istikrarlı ve başarılı bir öğrenme süreci gerçekleştirdiğini göstermektedir. Genel olarak modelin iyi optimize edildiği ve dengeli bir öğrenme performansı sergilediği söylenebilir.



Şekil 6.23. Xception Doğruluk Kayıp Grafikleri

Şekil 6.24'de Gradyan Ağırlıklı Sınıf Aktivasyon Haritalaması (Grad-CAM) ile orijinal görüntülerde lezyonun yer aldığı kısım, Grad-CAM çıktılarında da yoğun renkli (sıcak) bölgelerle vurgulanmıştır. Bu, modelin gerçekten hastalıklı bölgeye odaklandığını, rastgele arka plana değil lezyonun karakteristik özelliklerine baktığını göstermektedir.



Şekil 6.24. Xception Grad-CAM Analizi

6.8. MobileNetv2 Modeli Deneysel Çıktılar & Analiz Sonuçları

Bu çalışmada MobileNetv2 modeli, transfer öğrenme yaklaşımı ile kullanılmıştır. Toplam veritabanının %90'ı eğitim, %10'u test seti olarak ayrıldıktan sonra eğitim veri setinin de %10'u da doğrulama veri seti olarak ayrılmıştır. Toplam verilerin 6911 adeti eğitim, 768 adeti doğrulama ve 854 adeti de test amaçlı kullanılmıştır.

Tablo 6.22. MobileNetv2 Veri Dağılımı

Veri Türü	Yüzde (%)
Eğitim	81
Validasyon	9
Test	10

Modelin eğitimi sırasında kullanılan hiperparametre değerleri aşağıdaki şekilde gösterilmektedir. Çalışma boyunca modelin tüm eğitim verisi üzerinde 100 kere eğitilmiştir. Her seferde eğitime alınan örnek sayısı 32 olarak belirlenmiştir. Ağırlıkların güncellenme hızı 0.0001'dir. Aşırı öğrenmeyi önlemek için nöronların rastgele devre dışı bırakılma oranı 0.5 olarak belirlenmiştir. Modelin hangi olasılıkla bir sınıfa karar verdiğini belirleyen eşik 0.47 olarak algoritma analizi sonucunda optimal belirlenmiştir. Tam bağlantılı katmandaki nöron sayısı ise 256'dır.

Tablo 6.23. MobileNetv2 Hiperparametre Değerleri


Döngü	Yığın Boyutu	Öğrenme Oranı	Düşürme (Dropout)	Eşik Değeri	Nöron Sayısı
100	32	0.0001	0.5	0.47	256

Tablo 6.24.'de MobileNetv2 modelinin eğitim sonrası 854 örnekten oluşan test veri seti üzerindeki performans değerlendirmesi sunulmuştur. Model, sınıf 0 (maymun çiçeği olmayan) için %98.55 kesinlik (precision) ve %98.35 duyarlılık (recall) ile yüksek doğrulukta tahminlerde bulunmuş; sınıf 1 (maymun çiçeği) için ise %97.83 kesinlik ve %98.10 duyarlılık göstererek pozitif sınıfa karşı güçlü bir hassasiyet ortaya koymuştur. Bu performans, modelin iki sınıf arasında dengeli bir ayırım yapabildiğini göstermektedir. Makro ortalama değerler (her sınıfın eşit ağırlıkla değerlendirildiği durumda), %98.45 F1 skoru ile modelin genel olarak yüksek sınıflandırma başarısı sunduğunu ortaya koyarken; ağırlıklı ortalamalar (veri setindeki sınıf dağılımını dikkate alan ölçüm) üzerinden elde edilen %98,24 F1 skoru ise, modelin özellikle gerçek veri dağılımına duyarlı şekilde çalıştığını göstermektedir. Modelin genel doğruluk (accuracy) oranı %98.24 olarak hesaplanmıştır ve modelin doğru pozitif ve doğru negatif örnekleminin oldukça başarılı olduğunu göstermektedir. ROC eğrisi üzerinden Youden's J istatistiği yöntemiyle belirlenen 0.4701 eşik değeri ile, MobileNetv2 hem doğru pozitif oranını yüksek tutmak hem de gereksiz yanlış pozitifleri minimumda tutmak üzere istatistiksel olarak optimize edilmiş bir yaklaşım olduğu söylenebilir. Test verisi üzerindeki kayıp (loss) değeri 0.0655 ile oldukça düşük bir seviyede kalmış, bu da modelin tahmin çıktıları ile gerçek etiketler arasında güçlü bir örtüşme sağladığını ve aşırı öğrenme (overfitting) göstermediğini ortaya koymaktadır. Model boyutu 52.43 MB olan Inceptionv3, bu test işlemlerini NVIDIA Tesla T4 GPU üzerinde gerçekleştirmiştir. Donanım özellikleri arasında 16 GB RAM, GDDR6 bellek teknolojisi, 2560 CUDA çekirdeği ve 320 GBps bant genişliği yer almakta olup, bu altyapı modelin eğitim ve test süreçlerinde yüksek işlem verimliliği sağlamıştır. Sonuç olarak, MobileNetv2 modeli, yüksek doğruluk, dengeli sınıf tahmini ve düşük kayıp oranıyla, özellikle tıbbi görüntü sınıflandırma uygulamalarında güvenle kullanılabilir güçlü bir model olduğunu kanıtlamaktadır.

Tablo 6.24. MobileNetv2 Sınıflandırıcı Performans Çıktıları


Sınıf	Kesinlik	Duyarlılık	F1 Skoru	Veri Sayısı
0	0.9855	0.9835	0.9845	485
1	0.9783	0.9810	0.9797	369
Makro Ortalama	0.9820	0.9835	0.9845	854
Ağırlıklı Ortalama	0.9824	0.9824	0.9824	854
Genel Model Doğruluğu	0.9824 - %98.24			
Genel Model Kesinliği	0.9824			
Genel Model Duyarlılığı	0.9824			
Genel Model F1 Skoru	0.9824			
Eşik Değeri	0.4701			
Kayıp Değeri	0.0658			
Model Boyutu	52.43 MB			
Eğitim Süresi	2 saat, 19 dakika, 54 saniye			
Donanım Özellikleri	NVIDIA Tesla T4 GPU 16 GB RAM GDDR6 SDRAM Technology 2560 CUDA Cores 320 GBps Bandwith			

MobileNetv2 modelinin test verisi üzerindeki karışıklık matrisi (confusion matrix) Şekil 6.25’de gösterilmiştir. Toplamda 854 adet veriden oluşan örneklem içerisinde 479 görüntü, hem gerçekte sınıf “0” olup hem de model tarafından doğru şekilde sınıf “0” olarak tahmin edilmiştir. 6 görüntü gerçekte sınıf “0” olmasına rağmen model tarafından yanlışlıkla sınıf “1” olarak sınıflandırılmıştır. 10 görüntü ise gerçekte sınıf “1” olmasına rağmen model tarafından hatalı şekilde sınıf “0” olarak tahmin edilmiştir. Öte yandan, 359 görüntü, hem gerçekte sınıf “1” olup hem de doğru şekilde model tarafından sınıf “1” olarak sınıflandırılmıştır. Bu doğrultuda, doğru negatif (true negative) örnek sayısı 479, yanlış pozitif (false positive) sayısı 6, yanlış negatif (false negative) sayısı 10 ve doğru pozitif (true positive) örnek sayısı 359’dur. Yanlış pozitif oranı %1.24, yanlış negatif oranı da %2.71’dir. Bu sonuçlar, modelin hem negatif hem de pozitif sınıfları yüksek bir doğrulukla ayırt edebildiğini göstermektedir.




Şekil 6.25. MobileNetv2 Karışıklık Matrisi

Şekil 6.26’da model, 100 döngü boyunca hem eğitim hem doğrulama setinde hızla %70’ten %97–%98’e kadar yükselen doğruluk göstermektedir; doğrulama doğruluğu eğitimden bir miktar daha yüksek seyretmektedir. Kayıp eğrileri de paralel biçimde düşerek yaklaşık 0.07–0.08 seviyesine inmektedir. Bu, durum hem aşırı öğrenme olmadığını hem de güçlü bir genelleme kabiliyeti olduğunu işaret etmektedir.



Şekil 6.26. MobileNetv2 Doğruluk Kayıp Grafikleri

Şekil 6.27.'de Gradyan Ağırlıklı Sınıf Aktivasyon Haritalaması (Grad-CAM) ile orijinal görüntülerde lezyonun yer aldığı kısım, Grad-CAM çıktılarında da yoğun renkli (sıcak) bölgelerle vurgulanmıştır. Bu, modelin gerçekten hastalıklı bölgeye odaklandığını, rastgele arka plana değil lezyonun karakteristik özelliklerine baktığını göstermektedir.



Şekil 6.27. MobileNetv2 Grad-CAM Analizi

6.9. Meta Model Deneysel Çıktılar & Analiz Sonuçları

DenseNet169, DenseNet201 ve Xception modellerinden GAP katmanlarından çıkarılmış özellik vektörlerini bir araya getirerek geliştirilen yeni topluluk modeli (meta model), ayrı ayrı modellere göre test seti üzerinde daha iyi bir tahminleme performansı göstermiştir. Çalışmada veritabanının %90'ı eğitim, %10'u test seti olarak ayrıldıktan sonra eğitim veri setinin %10'u da doğrulama veri seti olarak ayrılmıştır. Toplam verilerin 6911 adeti eğitim, 768 adeti doğrulama ve 854 adeti de test amaçlı kullanılmıştır.

Tablo 6.25. Meta Model Veri Dağılımı

Veri Türü	Yüzde (%)
Eğitim	81
Validasyon	9
Test	10

Modelin eğitimi sırasında kullanılan hiperparametre değerleri aşağıdaki şekilde gösterilmektedir. Çalışma boyunca modelin tüm eğitim verisi üzerinde 100 kere eğitilmiştir. Her seferde eğitime alınan örnek sayısı 32 olarak belirlenmiştir. Ağırlıkların güncellenme hızı 0.0005'dir. Algoritmada öğrenme oranı azaltma işlemi uygulanmış olup, doğrulama kaybı üst üste 5 dönem iyileşmezse öğrenme oranı %50 düşürülmüştür ve öğrenme süreci optimize edilmiştir. Aşırı öğrenmeyi önlemek için nöronların rastgele devre dışı bırakılma oranı dal bloklarda 0.3 ve 0.4, birleşik bloklarda ise 0.5 olarak belirlenmiştir. Modelin hangi olasılıkla bir sınıfa karar verdiğini belirleyen eşik 0.8204 olarak algoritma analizi sonucunda optimal belirlenmiştir. Her bir özellik dalında önce 1024, ardından 512 nöronlu iki Yoğun (Dense) katman yer alır; kısa yol (residual) bağlantısı için de 512 nöronlu bir katman bulunmaktadır. Bu üç dalın çıktıları birleştirildikten sonra gelen tam bağlantılı (Dense) katmanlarda sırasıyla 512, 256 ve 128 nöron kullanılmaktadır. Aşağıdaki tabloda model eğitiminde algoritmada kullanılan hiperparametre değerleri gösterilmiştir.

Tablo 6.26. Meta Model Hiperparametre Değerleri


Döngü	Yığın Boyutu	Öğrenme Oranı	Düşürme (Dropout)	Eşik Değeri	Nöron Sayısı
100	32	0.0005	0,3, 0,4, 0,5	0.82	512, 256, 128

Tablo 6.27.'de meta modelinin eğitim sonrası 854 örnekten oluşan test veri seti üzerindeki performans değerlendirmesi sunulmuştur. Model, sınıf 0 (maymun çiçeği olmayan) için %98.78 kesinlik (precision) ve %100 duyarlılık (recall) ile yüksek doğrulukta tahminlerde bulunmuş; sınıf 1 (maymun çiçeği) için ise %100 kesinlik ve %98.37 duyarlılık göstererek pozitif sınıfa karşı güçlü bir hassasiyet ortaya koymuştur. Bu performans, modelin iki sınıf arasında çok dengeli bir ayırım yapabildiğini göstermektedir. Makro ortalama değerler (her sınıfın eşit ağırlıkla değerlendirildiği durumda), %99.28 F1 skoru ile modelin genel olarak yüksek sınıflandırma başarısı sunduğunu ortaya koyarken; ağırlıklı ortalamalar (veri setindeki sınıf dağılımını dikkate alan ölçüm) üzerinden elde edilen %99.30 F1 skoru ise, modelin özellikle gerçek veri dağılımına duyarlı şekilde çalıştığını göstermektedir. Modelin genel doğruluk (accuracy) oranı %99.30 olarak hesaplanmıştır ve modelin doğru pozitif ve doğru negatif örneklerinin oldukça başarılı olduğunu göstermektedir. ROC eğrisi üzerinden Youden's J istatistiği yöntemiyle belirlenen 0.8204 eşik değeri ile, modelin pozitif sınıf tahmininde daha dikkatli davrandığını göstermektedir. Test verisi üzerindeki kayıp (loss) değeri 0'a oldukça yaklaşmaktadır ve bu da modelin tahmin çıktıları ile gerçek etiketler arasında güçlü bir örtüşme sağladığını ve aşırı öğrenme (overfitting) göstermediğini ortaya koymaktadır. Boyutu 128.31 MB olan meta model, bu test işlemlerini NVIDIA Tesla T4 GPU üzerinde gerçekleştirmiştir. Donanım özellikleri arasında 16 GB RAM, GDDR6 bellek teknolojisi, 2560 CUDA çekirdeği ve 320 GBps bant genişliği yer almakta olup, bu altyapı modelin eğitim ve test süreçlerinde yüksek işlem verimliliği sağlamıştır. Sonuç olarak, meta model, yüksek doğruluk, dengeli sınıf tahmini ve düşük kayıp oranıyla, özellikle tıbbi görüntü sınıflandırma uygulamalarında güvenle kullanılabilir güçlü bir model olduğunu kanıtlamaktadır.

Tablo 6.27. Meta Model Sınıflandırıcı Performans Çıktıları

Sınıf	Kesinlik	Duyarlılık	F1 Skoru	Veri Sayısı
0	0.9878	1.0000	0.9939	485
1	1.0000	0.9837	0.9918	369
Makro Ortalama	0.9939	0.9919	0.9928	854
Ağırlıklı Ortalama	0.9931	0.9930	0.9930	854
Genel Model Doğruluğu	0.9930- %99.30			
Genel Model Kesinliği	0.9931			
Genel Model Duyarlılığı	0.9930			
Genel Model F1 Skoru	0.9930			
Eşik Değeri	0.8204			
Model Boyutu	128.31 MB			
Eğitim Süresi	2 saat, 37 dakika, 19 saniye			
Donanım Özellikleri	NVIDIA Tesla T4 GPU 16 GB RAM GDDR6 SDRAM Technology 2560 CUDA Cores 320 GBps Bandwith			

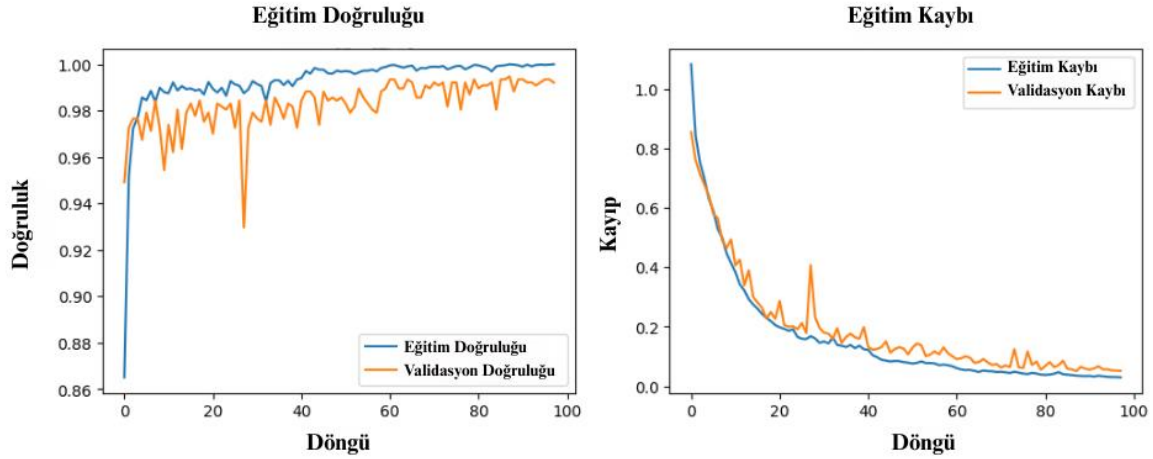
Meta modelin test verisi üzerindeki karışıklık matrisi (confusion matrix) Şekil 6.28.'de gösterilmiştir. Toplamda 854 adet veriden oluşan örneklem içerisinde 485 görüntü, hem gerçekte sınıf “0” olup hem de model tarafından doğru şekilde sınıf “0” olarak tahmin edilmiştir. 0 görüntü gerçekte sınıf “0” olmasına rağmen model tarafından yanlışlıkla sınıf “1” olarak sınıflandırılmıştır. 6 görüntü ise gerçekte sınıf “1” olmasına rağmen model tarafından hatalı şekilde sınıf “0” olarak tahmin edilmiştir. Öte yandan, 363 görüntü, hem gerçekte sınıf “1” olup hem de doğru şekilde model tarafından sınıf “1” olarak sınıflandırılmıştır. Bu doğrultuda, doğru negatif (true negative) örnek sayısı 485, yanlış pozitif (false positive) sayısı 0, yanlış negatif (false negative) sayısı 6 ve doğru pozitif (true positive) örnek sayısı 363’tür. Yanlış pozitif oranı %0.00, yanlış negatif oranı da %1.63’tür. Bu sonuçlar, modelin hem negatif hem de pozitif sınıfları yüksek bir doğrulukla ayırt edebildiğini göstermektedir.



Şekil 6.28 Meta Model Karışıklık Matrisi


Özellik düzeyinde topluluk öğrenmesi yöntemiyle geliştirilen modelin eğitim doğruluğu zamanla 1’ e yaklaşmıştır. Doğrulama doğruluğu da genellikle yüksek seviyelerde seyretmiş; fakat eğitim doğruluğuna göre biraz daha dalgalı ilerlemiştir. Bu durum, modelin aşırı öğrenme (overfitting) eğiliminde olmadığını, doğrulama performansının da ilerleyen döngülerde istikrarlı olduğunu göstermektedir. Eğitim kaybı döngü boyunca istikrarlı olarak azalarak 0’a oldukça yakınsamaktadır. Doğrulama kaybı da düzenli düşüş göstermiştir.

Doğrulama kaybı eğiliminin düşüş yönünde olmasından dolayı doğrulama kararlılığı iyi olarak değerlendirilebilir. Son döngü seviyelerinde doğrulama kaybı ile eğitim kaybının çok düşük seviyelere indiği, eğitim kaybına yakın seyrettiği gözlemlenmiştir.



Şekil 6.29. Meta Model Doğrulama Kayıp Grafikleri

Şekil 6.30.'da Gradyan Ağırlıklı Sınıf Aktivasyon Haritalaması (Grad-CAM) ile orijinal görüntülerde lezyonun yer aldığı kısım, Grad-CAM çıktılarında da yoğun renkli (sıcak) bölgelerle vurgulanmıştır. Bu, modelin gerçekten hastalıklı bölgeye odaklandığını, rastgele arka plana değil lezyonun karakteristik özelliklerine baktığını göstermektedir.



Grad-CAM Algoritması Analiz Çıktıları

Şekil 6.30 Meta Model Grad-CAM Analizi

7. LİTERATÜR KARŞILAŞTIRMASI

Tablo 7.1. Literatür Karşılaştırması

Yazarlar	Kullanılan Model	Doğruluk Oranı
Ahsan vd. [26]	VGG16	%97.00
Bala vd. [23]	Derin CNN Modeli	%93.19
Shams Nafisa Ali vd. [11]	ResNet50	%82.96
Veysel Harun ŞAHİN vd. [20]	MobileNetV2	%91.11
Chiranjibi Sitaula vd. [66]	Oylama Topluluk Öğrenmesi [DenseNet169 + Xception]	%87.13
Önerilen Yöntem	Meta Model	%99.30

Tablo 7.1’de literatürde etki yaratmış makaleler ele alınmıştır ve yayınlarda kullanılan model/modeller ve doğruluk performans değerlerine yer verilmiştir. Bu çalışmada, 8 adet derin öğrenme modeli ile yapılan ön test işlemleri sonrasında test seti üzerinde en iyi genelleme performansı sunan DenseNet169, DenseNet201 ve Xception modelleri üzerinden özellik düzeyi yığınlama topluluk öğrenmesi yaklaşımıyla geliştirilen meta modelin, ayrı ayrı modellerden daha iyi tahminleme yapabildiği gözlemlenmiştir. Meta modelin literatürdeki başarılı örneklerine kıyasla daha yüksek bir doğruluk gösterdiği de tabloda ortaya konmaktadır. Geliştirilen hibrit veri seti ve yığınlama topluluk öğrenmesi yöntemiyle elde edilen model, alanında literatürde yenilikçi bir imzaya yer vermektedir.

8. SONUÇ

Afrika kıtasında ortaya çıkan ve uzun süre Afrika kıtasında varlığını gösteren maymun çiçeği hastalığı (monkeypox disease), önce ABD ve sonrasında da 2022 yılında dünyaya yayılmış bulaşıcı bir hastalıktır. COVID-19 pandemisi dünya üzerinde ciddi hasarlara neden olmuştur ve özellikle bulaşıcı hastalıkların hızlı teşhisi yeni pandemilerin oluşmaması için büyük önem arz etmektedir. Hastalığın 2022 yılında dünya genelinde hızlıca yayılması ile Dünya Sağlık Örgütü (World Health Organization) Uluslararası Öne Sahip Halk Sağlığı Acil Durumu (PHEIC) ilan etmiştir ve uluslararası iş birliği vurgusu yapılmıştır. Hastalığın teşhisinde altın standart olarak bilinen polimeraz zincir reaksiyonu (PCR) ve diğer biyokimyasal testler; maliyet, zaman, tecrübeli personelin olmaması, ulaşım altyapısının yetersiz olması nedenlerinden dolayı özellikle gelişmemiş veya az gelişmiş coğrafyalarda kullanıma uygun olmayabilir.

Yapay zekâ, insanlığın problemlerini çözmek için araştırmacılar ve bilim insanları tarafından her geçen zaman geliştiriliyor. Hastanın imaj görüntüsünden özellikle tümör, lezyon, mikrokalsifikasyon veya polip gibi istenmeyen oluşumları tespit etmek adına bilgisayar destekli yapay zekâ çözümleri mevcuttur. İlgili uygulamalar sunuculara kurulup, lokal veya merkezi pacs sunucuları üzerinden görüntüleri değerlendirerek klinisyenlere çıktılarını ulaştırmaktadır. Maymun çiçeği hastalığının teşhisi için de yapay zekâ destekli sistemler geliştirilip, mobil veya web tabanlı sistemler üzerinde hastanın hastaneye gelmesine gerek kalmadan evinde ön teşhis yapma imkanı sunabilir.

Bu çalışmada, maymun çiçeği hastalığının cilt görüntüleri üzerinden tespit edilmesi için literatür ve açık veri tabanı kaynaklarından yararlanılarak yenilikçi ve özgün hibrit veritabanı geliştirilmiştir. Veritabanı içerisinde yapılan görüntü işleme faaliyetleri sonrasında veri artırma (data augmentation) işlemi uygulanmıştır. Veri artırma işlemi sonrasında 8533 adet cilt görüntüsünden oluşan veri seti elde edilmiştir. Veri tarafında ön işleme, veri artırma adımları uygulandıktan sonra transfer öğrenme yaklaşımı kullanılarak önceden eğitilmiş DenseNet121, DenseNet169, DenseNet201, VGG16, VGG19, Xception, Inceptionv3, MobileNetv2 derin öğrenme modelleri kullanılmıştır. Yapılan deney

faaliyetleri sonucunda DenseNet 169, DenseNet201 ve Xception modellerinin sırasıyla %98.48, %98.95 ve %98.24 test veri seti üzerinde doğruluğa ulaştığı gözlemlenmiştir.

İlgili modeller veri seti üzerinde literatürdeki örneklerinin de ötesinde bir başarı ortaya koymuştur; ancak çalışmamızın diğer bir gayesi de bu performans değerinin de ötesine çıkacak yanlış pozitif ve yanlış negatif örnek sayısını minimize edecek bir yaklaşım geliştirmektir. Bu amaç doğrultusunda, özellik seviyesinde topluluk öğrenmesi yaklaşımıyla DenseNet169, DenseNet201 ve Xception modellerinin GAP katmanından elde edilen özellik vektörleri bir araya getirilerek üst düzeyde bir sınıflandırıcı geliştirilmiştir. Yeni sınıflandırıcının (meta model), test seti üzerinde %99.30 doğruluğa ulaşarak ayrı ayrı modellerin de üstünde bir performans sergilemiştir. Literatüre yeni ve büyük veri seti ile ve de aynı zamanda geliştirilmiş özel model mimarisi ile sadece maymun çiçeği hastalığı için değil sağlık bilişimi alanında diğer problemlerin çözümünde önemli bir ışık tutacağına inanıyoruz.

Bu çalışma, topluluk öğrenmesi yaklaşımları ile geliştirilen modellerin, nesne tanıma uygulamalarında veya diğer yapay zekâ uygulamalarında sınıflandırma performansını geliştirme hususunda önemine işaret etmektedir.

9. ÖNERİ

Bu tezde, literatüre katkı sunmak amacıyla teorik çalışma gerçekleştirilmiştir. Maymun çiçeği hastalığı ile ilgili açık kaynaklar üzerinde pratik anlamda model geliştirip, gerçek dünyada kullanmak adına yeterli veri yer almamaktadır. Sağlık verilerine erişim, hukuki ve mevzuat prosedürlerinden dolayı kolay değildir ve mutlaka bir uzman heyet tarafından edinilen veriler de valide edilmelidir. Teorik çalışma özelinde, veri adetinin ve çeşitliliğinin artırılması model performansını olumlu etkileyebilir. Çalışmada sadece görsel verilerden yararlanılarak bilgisayarlı görü işlemi yapılmıştır; ancak görsel dışında yaş, cinsiyet, bölge gibi veriler de işlenirse çok daha güçlü ve etkili modeller oluşturulabilir. Web veya mobil uygulamalar için geliştiriciler, uygulama boyutu vb. uygulama performansını ve kullanıcı memnuniyetini etkileyecek birçok parametreyi de dikkate almalıdır.

KAYNAKLAR

- [1] J. Guarner, C. del Rio, and P. N. Malani, “Monkeypox in 2022—What Clinicians Need to Know,” *JAMA*, vol. 328, no. 2, p. 139, Jul. 2022.
- [2] A. Kantele, K. Chickering, O. Vapalahti, and A. W. Rimoin, “Emerging diseases—the monkeypox epidemic in the Democratic Republic of the Congo,” *Clinical Microbiology and Infection*, vol. 22, no. 8, pp. 658–659, Aug. 2016.
- [3] D. L. Heymann, M. Szczeniowski, and K. Esteves, “Re-emergence of monkeypox in Africa: a review of the past six years,” *Br Med Bull*, vol. 54, no. 3, pp. 693–702, Jan. 1998.
- [4] M. G. Reynolds *et al.*, “Spectrum of Infection and Risk Factors for Human Monkeypox, United States, 2003,” *Emerg Infect Dis*, vol. 13, no. 9, pp. 1332–1339, Sep. 2007.
- [5] A. M. Vaughan *et al.*, “A large multi-country outbreak of monkeypox across 41 countries in the WHO European Region, 7 March to 23 August 2022,” *Eurosurveillance*, vol. 27, no. 36, Sep. 2022.
- [6] M. Nakhaie, N. Arefinia, J. Charostad, D. Bashash, M. Haji Abdolvahab, and M. Zarei, “Monkeypox virus diagnosis and laboratory testing,” *Rev Med Virol*, vol. 33, no. 1, Jan. 2023.
- [7] J. Qu *et al.*, “A Comparative Evaluation of Three Diagnostic Assays for the Detection of Human Monkeypox,” *Viruses*, vol. 16, no. 8, p. 1286, Aug. 2024.
- [8] E. K. Oladipo *et al.*, “Laboratory diagnosis of COVID-19 in Africa: availability, challenges and implications,” *Drug Discov Ther*, vol. 14, no. 4, pp. 153–160, Aug. 2020.
- [9] W. Zhao, W. Jiang, and X. Qiu, “Deep learning for COVID-19 detection based on CT images,” *Sci Rep*, vol. 11, no. 1, p. 14353, Jul. 2021.

- [10] A. S. Jaradat *et al.*, “Automated Monkeypox Skin Lesion Detection Using Deep Learning and Transfer Learning Techniques,” *Int J Environ Res Public Health*, vol. 20, no. 5, p. 4422, Mar. 2023.
- [11] S. N. Ali *et al.*, “Monkeypox Skin Lesion Detection Using Deep Learning Models: A Feasibility Study,” Jul. 2022.
- [12] A. S. Jaradat *et al.*, “Automated Monkeypox Skin Lesion Detection Using Deep Learning and Transfer Learning Techniques,” *Int J Environ Res Public Health*, vol. 20, no. 5, p. 4422, Mar. 2023.
- [13] C. T. Cho and H. A. Wenner, “Monkeypox virus,” *Bacteriol Rev*, vol. 37, no. 1, pp. 1–18, Mar. 1973.
- [14] J. G. Breman, Kalisa-Ruti, M. V Steniowski, E. Zanotto, A. I. Gromyko, and I. Arita, “Human monkeypox, 1970-79.,” *Bull World Health Organ*, vol. 58, no. 2, pp. 165–82, 1980
- [15] E. Gross, “Update on emerging infections: news from the Centers for Disease Control and prevention. Update: Multistate outbreak of monkeypox--Illinois, Indiana, Kansas, Missouri, Ohio, and Wisconsin, 2003.,” *Ann Emerg Med*, vol. 42, no. 5, pp. 660–2; discussion 662-4, Nov. 2003.
- [16] I. Gul *et al.*, “Current and Perspective Sensing Methods for Monkeypox Virus,” *Bioengineering*, vol. 9, no. 10, p. 571, Oct. 2022.
- [17] M. Siar and M. Teshnehlal, “Brain Tumor Detection Using Deep Neural Network and Machine Learning Algorithm,” in *2019 9th International Conference on Computer and Knowledge Engineering (ICCKE)*, IEEE, Oct. 2019, pp. 363–368.
- [18] A. M. McCollum and I. K. Damon, “Human Monkeypox,” *Clinical Infectious Diseases*, vol. 58, no. 2, pp. 260–267, Jan. 2014.
- [19] C. A. Petti, C. R. Polage, T. C. Quinn, A. R. Ronald, and M. A. Sande, “Laboratory Medicine in Africa: A Barrier to Effective Health Care,” *Clinical Infectious Diseases*, vol. 42, no. 3, pp. 377–382, Feb. 2006.

- [20] Sahin, V. H., Oztel, I., & Yolcu Oztel, G. (2022). Human monkeypox classification from skin lesion images with deep pre-trained network using mobile application. *Journal of medical systems*, 46(11), 79.
- [21] S. N. Ali *et al.*, “A Web-based Mpox Skin Lesion Detection System Using State-of-the-art Deep Learning Models Considering Racial Diversity,” Jun. 2023.
- [22] M. K. Tripathi, A. Nath, T. P. Singh, A. S. Ethayathulla, and P. Kaur, “Evolving scenario of big data and Artificial Intelligence (AI) in drug discovery,” *Mol Divers*, vol. 25, no. 3, pp. 1439–1460, Aug. 2021.
- [23] D. Bala *et al.*, “MonkeyNet: A robust deep convolutional neural network for monkeypox disease detection and classification,” *Neural Networks*, vol. 161, pp. 757–775, Apr. 2023.
- [24] (2023). Dermnet. Accessed: Sep. 2023. [Online]. Available: “<http://www.dermnet.com/>”
- [25] A. Nasayrah, “Data Monkeypox,” Kaggle.com. “<https://www.kaggle.com/datasets/ahmadnasayrah/data-monkeypox>” (accessed: Sep. 8, 2025).
- [26] Ahsan, M. M., Uddin, M. R., Farjana, M., Sakib, A. N., Momin, K. A., & Luna, S. A. (2022). Image Data collection and implementation of deep learning-based model in detecting Monkeypox disease using modified VGG16.
- [27] S. C. Wong, A. Gatt, V. Stamatescu, and M. D. McDonnell, “Understanding Data Augmentation for Classification: When to Warp?,” in *2016 International Conference on Digital Image Computing: Techniques and Applications (DICTA)*, IEEE, Nov. 2016, pp. 1–6.
- [28] L. Perez and J. Wang, “The Effectiveness of Data Augmentation in Image Classification using Deep Learning,” Dec. 2017.
- [29] C. Janiesch, P. Zschech, and K. Heinrich, “Machine learning and deep learning,” *Electronic Markets*, vol. 31, no. 3, pp. 685–695, Sep. 2021.

- [30] Dr. Sheshang Degadwala and Dhairya Vyas, “Systematic Analysis of Deep Learning Models vs. Machine Learning,” *International Journal of Scientific Research in Computer Science, Engineering and Information Technology*, vol. 10, no. 4, pp. 60–70, Jul. 2024.
- [31] N. Wolchover, “AI recognizes cats the same way physicists calculate the cosmos,” *Wired.com*, Dec. 15, 2014. [Online]. Available: “<https://www.wired.com/2014/12/ai-recognizes-cats-the-same-way-physicists-calculate-the-cosmos/>.”
- [32] D. Bashir, G. D. Montanez, S. Sehra, P. S. Segura, and J. Lauw, “An Information-Theoretic Perspective on Overfitting and Underfitting,” Nov. 2020.
- [33] S.-J. Heo, Z. Chunwei, and E. Yu, “Response Simulation, Data Cleansing and Restoration of Dynamic and Static Measurements Based on Deep Learning Algorithms,” *Int J Concr Struct Mater*, vol. 12, no. 1, p. 82, Dec. 2018.
- [34] D. Dablain, B. Krawczyk, and N. V. Chawla, “DeepSMOTE: Fusing Deep Learning and SMOTE for Imbalanced Data,” *IEEE Trans Neural Netw Learn Syst*, vol. 34, no. 9, pp. 6390–6404, Sep. 2023.
- [35] S. Salman and X. Liu, “Overfitting Mechanism and Avoidance in Deep Neural Networks,” Jan. 2019.
- [36] C. S. Miranda and F. J. Von Zuben, “Reducing the Training Time of Neural Networks by Partitioning,” Jan. 2016.
- [37] D. Sönmez, “Geri yayılım algoritması’na matematiksel yaklaşım,” *DerinOglenme.com*, Jun. 28, 2018. [Online]. Available: “<https://www.derinogrenme.com/2018/06/28/geri-yayilim-algoritmasina-matematiksel-yaklasim/>.”
- [38] Y. LeCun, Y. Bengio, and G. Hinton, “Deep learning,” *Nature*, vol. 521, no. 7553, pp. 436–444, May 2015.
- [39] B. KAYA and M. ÖNAL, “A CNN Based Method for Detecting Covid-19 from CT Images,” *Computer Science*, Sep. 2021.

- [40] A. Tiwari, “Supervised learning: From theory to applications,” in *Artificial Intelligence and Machine Learning for EDGE Computing*, Elsevier, 2022, pp. 23–32.
- [41] “Supervised machine learning,” GeeksforGeeks, Jul. 11, 2025. [Online]. Available: “<https://www.geeksforgeeks.org/machine-learning/supervised-machine-learning/>”
- [42] W. S. McCulloch and W. Pitts, “A logical calculus of the ideas immanent in nervous activity,” *Bull Math Biophys*, vol. 5, no. 4, pp. 115–133.
- [43] M. F. Keskenler and E. F. Keskenler, “Geçmişten günümüze yapay sinir ağları ve tarihçesi,” *Takvim-i Vekayi*, vol. 5, no. 2, pp. 8–18, 2017.
- [44] K. Fukushima, “Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position,” *Biol Cybern*, vol. 36, no. 4, pp. 193–202, Apr. 1980.
- [45] Y. Lecun, L. Bottou, Y. Bengio, and P. Haffner, “Gradient-based learning applied to document recognition,” *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278–2324, 1998.
- [46] A. Krizhevsky, I. Sutskever, and G. E. Hinton, “ImageNet classification with deep convolutional neural networks,” *Commun ACM*, vol. 60, no. 6, pp. 84–90, May 2017.
- [47] I. Goodfellow, Y. Bengio, and A. Courville, *Deep learning*. Cambridge, MA, USA: MIT Press, 2016.
- [48] R. Yamashita, M. Nishio, R. K. G. Do, and K. Togashi, “Convolutional neural networks: an overview and application in radiology,” *Insights Imaging*, vol. 9, no. 4, pp. 611–629, Aug. 2018.
- [49] A. Zafar *et al.*, “Convolutional Neural Networks: A Comprehensive Evaluation and Benchmarking of Pooling Layer Variants,” *Symmetry (Basel)*, vol. 16, no. 11, p. 1516, Nov. 2024.

- [50] V. Kunc and J. Kléma, “Three Decades of Activations: A Comprehensive Survey of 400 Activation Functions for Neural Networks,” Feb. 2024.
- [51] D. Soydaner, “A Comparison of Optimization Algorithms for Deep Learning,” Jul. 2020.
- [52] H. Robbins and S. Monro, “A Stochastic Approximation Method,” *The Annals of Mathematical Statistics*, vol. 22, no. 3, pp. 400–407, Sep. 1951.
- [53] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, “Learning representations by back-propagating errors,” *Nature*, vol. 323, no. 6088, pp. 533–536, Oct. 1986.
- [54] D. P. Kingma and J. Ba, “Adam: A Method for Stochastic Optimization,” Jan. 2017.
- [55] M. Hadjal, E. Medina-Lopez, J. Ren, A. Gallego, and D. McKee, “An Artificial Neural Network Algorithm to Retrieve Chlorophyll a for Northwest European Shelf Seas from Top of Atmosphere Ocean Colour Reflectance,” *Remote Sens (Basel)*, vol. 14, no. 14, p. 3353, Jul. 2022.
- [56] F. Chollet, “Xception: Deep Learning with Depthwise Separable Convolutions,” in *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, IEEE, Jul. 2017, pp. 1800–1807.
- [57] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, “Rethinking the Inception Architecture for Computer Vision,” in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, IEEE, Jun. 2016, pp. 2818–2826.
- [58] A. G. Howard *et al.*, “MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications,” Apr. 2017.
- [59] G. Huang, Z. Liu, L. Van Der Maaten, and K. Q. Weinberger, “Densely Connected Convolutional Networks,” in *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, IEEE, Jul. 2017, pp. 2261–2269.
- [60] K. Simonyan and A. Zisserman, “Very Deep Convolutional Networks for Large-Scale Image Recognition,” Apr. 2015.

- [61] M. Sokolova and G. Lapalme, "A systematic analysis of performance measures for classification tasks," *Inf Process Manag*, vol. 45, no. 4, pp. 427–437, Jul. 2009.
- [62] Taspinar, Y. S., Cinar, I., Kursun, R., & Koklu, M. Monkeypox Skin Lesion Detection with Deep Learning Models and Development of Its Mobile Application. *Public health*, 500, 5.
- [63] A. H. Thieme *et al.*, "A deep-learning algorithm to classify skin lesions from mpox virus infection," *Nat Med*, vol. 29, no. 3, pp. 738–747, Mar. 2023.
- [64] A. Akram *et al.*, "SkinMarkNet: an automated approach for prediction of monkeyPox using image data augmentation with deep ensemble learning models," *Multimed Tools Appl*, vol. 84, no. 18, pp. 20177–20193, Jul. 2024.
- [65] S. Maqsood, R. Damaševičius, S. Shahid, and N. D. Forkert, "MOX-NET: Multi-stage deep hybrid feature fusion and selection framework for monkeypox classification," *Expert Syst Appl*, vol. 255, p. 124584, Dec. 2024.
- [66] C. Sitaula and T. B. Shahi, "Monkeypox Virus Detection Using Pre-trained Deep Learning-based Approaches," *J Med Syst*, vol. 46, no. 11, p. 78, Oct. 2022.
- [67] M. M. Ahsan *et al.*, "Enhancing Monkeypox diagnosis and explanation through modified transfer learning, vision transformers, and federated learning," *Inform Med Unlocked*, vol. 45, p. 101449, 2024.
- [68] M. Altun, H. Gürüler, O. Özkaraca, F. Khan, J. Khan, and Y. Lee, "Monkeypox Detection Using CNN with Transfer Learning," *Sensors*, vol. 23, no. 4, p. 1783, Feb. 2023.
- [69] S. Asif, M. Zhao, F. Tang, Y. Zhu, and B. Zhao, "Metaheuristics optimization-based ensemble of deep neural networks for Mpox disease detection," *Neural Networks*, vol. 167, pp. 342–359, Oct. 2023.
- [70] S. Becker and M. Plumbley, "Unsupervised neural network learning procedures for feature extraction and classification," *Applied Intelligence*, vol. 6, no. 3, pp. 185–203, Jul. 1996.

- [71] J. Yao, "Vehicle Classification Enhancement Through Data Augmentation and Model Fusion: A Study of Deep Learning Approaches," in *2024 4th International Conference on Digital Society and Intelligent Systems (DSInS)*, IEEE, Nov. 2024, pp. 449–453.
- [72] M. Lin, Q. Chen, and S. Yan, "Network In Network," Mar. 2014.
- [73] Malviya, A. V., & Ladhake, S. A. (2016, August). Region duplication detection using color histogram and moments in digital image. In *2016 International Conference on Inventive Computation Technologies (ICICT)* (Vol. 1, pp. 1-4).
- [74] M. Wahid, N. Ahmad, M. H. Zafar, and S. Khan, "On combining MD5 for image authentication using LSB substitution in selected pixels," in *2018 International Conference on Engineering and Emerging Technologies (ICEET)*, IEEE, Feb. 2018, pp. 1–6.