

T.C.
BİLECİK ŞEYH EDEBALI ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**DERİN ÖĞRENME ALGORİTMALARI İLE YUMURTALIKLARDA KANSERLİ
HÜCRE TESPİTİ**

YÜKSEK LİSANS TEZİ

HAZAL PARLAK

TEZ DANIŞMANI

DR. ÖĞR. ÜYESİ BURAKHAN ÇUBUKÇU

BİLECİK, 2024

10647142

T.C.
BİLECİK ŞEYH EDEBALI ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**DERİN ÖĞRENME ALGORİTMALARI İLE YUMURTALIKLARDA KANSERLİ
HÜCRE TESPİTİ**

YÜKSEK LİSANS TEZİ

HAZAL PARLAK

TEZ DANIŞMANI

DR. ÖĞR. ÜYESİ BURAKHAN ÇUBUKÇU

BİLECİK, 2024
10647142

BEYAN

Derin Öğrenme Algoritmaları İle Yumurtalıklarda Kanserli Hücre Tespiti adlı yüksek lisans tezinin hazırlık ve yazımı sırasında bilimsel araştırma ve etik kurallarına uyduğumu, başkalarının eserlerinden yararlandığım bölümlerde bilimsel kurallara uygun olarak atıfta bulunduğumu, kullandığım verilerde herhangi bir tahrifat yapmadığımı, tezin herhangi bir kısmının Bilecik Şeyh Edebali Üniversitesi veya başka bir üniversitede başka bir tez çalışması olarak sunulmadığını, aksinin tespit edileceği muhtemel durumlarda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Bu çalışmanın, Bilimsel Araştırma Projeleri (BAP), TÜBİTAK veya benzeri kuruluşlarca desteklenmesi durumunda; projenin ve destekleyen kurumun adı proje numarası ile, ETİK KURUL onayı alınması durumunda ise ETİK KURUL tarih karar ve sayı bilgilerinin beyan edilmesi gerekmektedir.			
DESTEK ALINMIŞTIR		DESTEK ALINMAMIŞTIR	X
Destek alındı ise;			
Destekleyen kurum;			
Desteğin Türü		Proje Numarası	
1- BAP (Bilimsel Araştırma Projesi)			
2- TÜBİTAK			
Diğer;.....			
ETİK KURUL onayı var ise;			
ETİK KURUL karar tarih/sayı:		/.....	

HAZAL PARLAK

Tarih

.....

İmza

.....

ÖN SÖZ

Bu tez çalışmasının tamamlanmasında desteklerini esirgemeyen birçok kişi ve şahsa teşekkür etmeyi bir borç bilirim.

Öncelikle, bu araştırmanın her aşamasında bilgi ve deneyimleriyle bana rehberlik eden, her türlü desteği ve anlayışıyla yanımda olan değerli danışman hocam Sayın Dr. Öğr. Üyesi Burakhan ÇUBUKÇU 'ya en içten teşekkürlerimi sunarım. Kendisinin yol göstericiliği ve teşvik edici yaklaşımları olmasaydı, bu çalışmayı tamamlamak mümkün olmayabilirdi. Akademik hayatım boyunca bana ilham veren, araştırmaya olan tutkusuyla beni motive eden ve her zaman doğru yönlendirmeleriyle yolumu aydınlatan bir hocam olmuştur. Onun vizyonu ve bilimsel bakış açısı, bu çalışmanın kalitesini ve kapsamını büyük ölçüde artırmıştır. Kendisinin desteği ve sabrı için sonsuz minnettarım.

Ayrıca, çalışmamın değerlendirilmesinde katkıda bulunan jüri üyelerine, değerli zamanlarını ayırarak görüş ve önerileriyle bu araştırmayı daha ileriye taşımamı sağladıkları için teşekkür ederim. Kıymetli yorumları ve eleştirileri, çalışmamın kalitesini artırmada büyük rol oynamıştır.

Bu süreçte maddi ve manevi desteğini her zaman hissettiğim aileme sonsuz teşekkürlerimi sunarım. Özellikle anne ve babama, eğitim hayatım boyunca gösterdikleri sabır, anlayış ve destek için minnettarım. Onların varlığı ve sevgisi, bu yolculuğun her anında bana güç ve motivasyon kaynağı olmuştur. Son olarak, bu çalışmanın gerçekleştirilmesinde katkıda bulunan tüm arkadaşlarıma, meslektaşlarıma teşekkür ederim. Yardım ve destekleri, bu araştırmanın tamamlanmasında önemli bir rol oynamıştır.

Bu çalışmanın, yumurtalık kanseri hücrelerinin sınıflandırılmasında bilim dünyasına ve klinik uygulamalara katkı sağlamasını umut ediyorum.

Hazal PARLAK

2024

ÖZET

DERİN ÖĞRENME ALGORİTMALARI İLE YUMURTALIKLARDA KANSERLİ HÜCRE TESPİTİ

Bu çalışma, yumurtalık kanseri hücrelerini sınıflandırmak amacıyla çeşitli derin öğrenme mimarilerinin (ResNet-50, EfficientNetB0, DenseNet121, MobileNetV2 ve InceptionV3) performanslarını değerlendirmektedir. Her bir model, yumurtalık kanserinin beş farklı alt türüne (Clear Cell, Endometri, Mucinous, Non_Cancerous, Serous) ait veriler kullanılarak eğitildi ve test edildi. Veri seti eğitim, doğrulama ve test olarak üç ana bölüme ayrıldı ve veri artırma teknikleri kullanarak eğitim verisinin çeşitliliğini arttırılmıştır. Modellerin eğitimi sırasında modeller, önceden eğitilmiş ağırlıklarla yüklendi ve üst katmanları çıkarılarak özel sınıflandırıcı katmanlar eklendi. Eğitim sürecinde, sınıf ağırlıkları hesaplamaları, kategorik çapraz entropi kaybı ve ince ayar yöntemleri kullanılarak bu yöntemlerin başarımları da değerlendirilmiştir. Modellerin performansı, başarımlar grafikleri, sınıf bazlı sonuçlar ve karmaşıklık matrisleri ile gösterilmiş ve doğruluk, hassasiyet, geri çağırma ve F1-skoru metrikleri kullanılarak değerlendirilmiştir. Elde edilen sonuçlar, ince ayarlı modellerin genellikle daha iyi performans gösterdiğini ve belirli modellerin belirli sınıflar için daha uygun olduğunu göstermektedir. EfficientB0 modelinin tüm sınıflarda yüksek doğruluk oranlarına ulaştığı gözlemlenmiştir. Modelin genel doğruluğu %98,87'ye ulaşmıştır; bu sonuç, kanser sınıflandırmasında önerilen yöntemin umut verici olduğu şeklinde değerlendirilmektedir. EfficientB0 modelinden sonra başarımları en yüksek model ResNet50'dir. ResNet50, yüksek hassasiyet, geri çağırma, F1 skoru ve doğruluk elde ederken, makro ortalama değerleri diğer modellere göre daha yüksektir. Diğer modellerin performansı, bu iki modelin gerisinde kalmaktadır. Bu sonuçlar, ResNet50 ve EfficientB0'un önerilen modeller olarak değerlendirilmesini desteklemektedir. Çalışmanın sonuçları, derin öğrenme modellerinin yumurtalık kanseri sınıflandırması alanında etkin bir şekilde kullanılabileceğini ve gelecekteki çalışmalar için değerli bir rehberlik kaynağı olabileceğini göstermektedir. Bu sonuçlar, daha etkili ve hassas tanı yöntemlerinin geliştirilmesine yönelik önemli bir adım olarak değerlendirilebilir.

Anahtar Kelimeler: Derin Öğrenme, Transfer Öğrenim, Yumurtalık Kanseri, Sınıflandırma.

ABSTRACT

DETECTION OF CANCEROUS CELLS IN THE OVARIES USING DEEP LEARNING ALGORITHMS

This study evaluates the performance of various deep learning architectures (ResNet-50, EfficientNetB0, DenseNet121, MobileNetV2, and InceptionV3) for classifying ovarian cancer cells. Each model was trained and tested using data from five different subtypes of ovarian cancer (Clear Cell, Endometrioid, Mucinous, Non_Cancerous, Serous). The dataset was divided into three main parts: training, validation, and testing, with data augmentation techniques employed to increase the diversity of the training data. During the training process, pretrained weights were loaded, the top layers were removed, and custom classifier layers were added. The performance of these methods was evaluated using class weight calculations, categorical cross-entropy loss, and fine-tuning techniques. The models' performance was illustrated with performance graphs, class-based results, and confusion matrices, and assessed using accuracy, precision, recall, and F1-score metrics. The results indicated that fine-tuned models generally performed better and that certain models were more suitable for specific classes. The EfficientNetB0 model achieved high accuracy rates across all classes. The overall accuracy of this model reached 98.87%, suggesting that the proposed method for cancer classification is promising. Following EfficientNetB0, the ResNet-50 model showed the second-highest performance. ResNet-50 achieved high precision, recall, F1 score, and accuracy, with macro-average values higher than those of the other models. The performance of the other models was inferior to these two models. These findings support the consideration of ResNet-50 and EfficientNetB0 as the recommended models. The results of the study demonstrate that deep learning models can be effectively used in the classification of ovarian cancer and can serve as a valuable guide for future research. These outcomes represent an important step towards developing more effective and precise diagnostic methods.

Keywords: Deep Learning, Transfer Learning, Ovarian Cancer, Classification.

İÇİNDEKİLER

Sayfa No

ÖN SÖZ.....	i
ÖZET	ii
ABSTRACT	iii
İÇİNDEKİLER.....	iv
TABLolar LİSTESİ	vi
ŞEKİLLER LİSTESİ	vii
SİMGELER VE KISALTMALAR LİSTESİ	ix
1. GİRİŞ.....	1
2. YUMURTALIK KANSERİ.....	6
2.1 Yumurtalık Tümörleri	6
2.1.1 Epitel Yumurtalık Tümörleri	6
2.1.1.1 Yüksek Dereceli Seröz Karsinom.....	7
2.1.1.2 Endometrioid Karsinom	7
2.1.1.3 Berrak Hücreli Karsinom	7
2.1.1.4 Düşük Dereceli Seröz Karsinom	8
2.1.1.5 Müköz Karsinom	8
3. YUMURTALIK KANSERİ SINIFLANDIRMASINDA GÖRÜNTÜ İŞLEME VE YAPAY ZEKÂ TEKNİKLERİNİN KULLANIMI	9
3.1 Yapay Sinir Ağları.....	9
3.2 Derin Öğrenme	10
3.3 Evrişimli Sinir Ağları.....	10
3.4 Transfer Öğrenimi.....	11
3.4.1 Residual Neural Network (ResNet)	12
3.4.2 EfficientNet.....	13
3.4.3 Inception-V3.....	14
3.4.4 MobileNet-V2	15

3.4.5 DenseNet121	16
4. MATERYAL VE YÖNTEM	18
4.1 Veri Seti.....	19
4.2 Veri Önışleme ve Veri Arttırma.....	20
4.3 Modellerin Eğitimi Sırasında Kullanılan Yöntemler	21
4.3.1 Fine-Tuning (İnce ayar)	21
4.3.2 Kaybolma ve Erken Durdurma (Dropout, EarlyStopping).....	22
4.3.3 Sınıf Ağırlıkları (Class Weights)	23
4.3.4 Kayıp Fonksiyonu (Loss Function)	23
4.4 Kullanılan Öğrenme Aktarımı Yöntemleri ve Özelleştirmeleri.....	24
4.4.1 ResNet-50.....	25
4.4.2 EfficientB0	26
4.4.3 InceptionV3	26
4.4.4 MobileNetV2	27
4.4.5 DenseNet121	28
4.5 Değerlendirme Metrikleri.....	28
5. BULGULAR VE DEĞERLENDİRME.....	30
5.1 Resnet50 Mimarisi Sonuçlar	31
5.2 EfficientNetB0 Mimarisi Sonuçlar.....	36
5.3 InceptionV3 Mimarisi Sonuçları.....	40
5.4 MobileNetV2 Mimarisi Sonuçları.....	44
5.5 DenseNet121 Mimarisi Sonuçları.....	49
6. SONUÇ VE ÖNERİLER	56
KAYNAKÇA	60

TABLÖLAR LİSTESİ

Sayfa No

Tablo 4. 1. Derin öğrenme yöntemlerinin bazı özellikleri	25
Tablo 4. 2. Değerlendirme Metrikleri.....	29
Tablo 5. 1. ResNet50_Temel Sınıf Bazlı Sonuçlar	32
Tablo 5. 2. ResNet50_Ağırlıklı Sınıf Bazlı Sonuçlar	33
Tablo 5. 3. ResNet50_İnceAyarlı Sınıf Bazlı Sonuçlar.....	34
Tablo 5. 4. EfficientNetB0_Temel için Sınıf Bazlı Sonuçlar.....	37
Tablo 5. 5. EfficientNetB0_Ağırlıklı Sınıf Bazlı Sonuçlar	37
Tablo 5. 6. EfficientB0_İnceAyarlı Sınıf Bazlı Sonuçlar.....	38
Tablo 5. 7. InceptionV3_Temel Sınıf Bazlı Sonuçlar	41
Tablo 5. 8. InceptionV3_Ağırlıklı Sınıf Bazlı Sonuçlar.....	41
Tablo 5. 9. InceptionV3_İnceAyarlı Sınıf Bazlı Sonuçlar	42
Tablo 5. 10. MobileNetV2_Temel Sınıf Bazlı Sonuçlar	45
Tablo 5. 11. MobileNetV2_Ağırlıklı Sınıf Bazlı Sonuçlar	46
Tablo 5. 12. MobileNetV2_İnceAyarlı Sınıf Bazlı Sonuçlar	47
Tablo 5. 13. DenseNet121_Temel Sınıf Bazlı Sonuçlar	51
Tablo 5. 14. DenseNet121_Ağırlıklı Sınıf Bazlı Sonuçlar	51
Tablo 5. 15. DenseNet121_İnceAyar Sınıf Bazlı Sonuçlar	52
Tablo 5. 16. Kullanılan Modellerin Karşılaştırılması.....	54

ŞEKİLLER LİSTESİ

Sayfa No

Şekil 2.1. Yumurtalık karsinomlarının başlıca histolojik alt tipleri.....	7
Şekil 3.1. Çok Katmanlı İleri Beslemeli Yapay Sinir Ağı Modeli	9
Şekil 3. 2. Evrişimli Sinir Ağları Mimarisi	11
Şekil 3. 3. Maksimum Havuzlama İşlemi	11
Şekil 3. 4. Resnet-50 Mimarisi.....	12
Şekil 3. 5. Efficient-B0 Genel Mimarisi	14
Şekil 3. 6. Inception-V3 Mimarisi	15
Şekil 3. 7. MobileNetV2 Mimarisi	16
Şekil 4. 1. Çalışmanın Akış Diyagramı.....	19
Şekil 4. 2. İnce Ayarlı Tasarım Akış Diyagramı.....	19
Şekil 4. 3. Ovarian Cancer & Subtypes veri setinden örnek histopatolojik görüntüler	20
Şekil 4. 4. Veri arttırma teknikleri sonrasında elde edilen örnek görüntüler	21
Şekil 5. 1. ResNet50 Kayıp ve Doğruluk Grafikleri	32
Şekil 5. 2. ResNet50_Temel Karmaşıklık Matrisi	34
Şekil 5. 3. ResNet50_Ağırlıklı Karmaşıklık Matrisi	35
Şekil 5. 4. ResNet50_İnceAyarlı Karmaşıklık Matrisi	35
Şekil 5. 5. EfficientNetB0 Kayıp ve Doğruluk Grafikleri	36
Şekil 5. 6. EfficientNetB0_Temel Karmaşıklık Matrisi	39
Şekil 5. 7. EfficientB0_Ağırlıklı Karmaşıklık Matrisi.....	39
Şekil 5. 8. InceptionV3 Kayıp ve Doğruluk Grafikleri.....	40
Şekil 5. 9. InceptionV3_Temel Karmaşıklık Matrisi	43
Şekil 5. 10. InceptionV3_Ağırlıklı Karmaşıklık Matrisi	43
Şekil 5. 11. InceptionV3_İnceAyar Karmaşıklık Matrisi	44
Şekil 5. 12. MobileNetV2 Doğruluk ve Kayıp Grafikleri.....	45
Şekil 5. 13. MobileNetV2 için Karmaşıklık Matrisi.....	47

Şekil 5. 14. MobileNetV2_Ağırlıklı Karmaşıklık Matrisi	48
Şekil 5. 15. MobileNetV2_İnceAyarlı Karmaşıklık Matrisi.....	49
Şekil 5. 16. DenseNet121 Doğruluk ve Kayıp Grafikleri	50
Şekil 5. 17. DenseNet121_Ağırlıklı Karmaşıklık Matrisi	52
Şekil 5. 18. DenseNet121_İnceAyarlı Karmaşıklık Matrisi	53
Şekil 5. 19. DenseNet121_İnceAyarlı Karmaşıklık Matrisi	53
Şekil 5. 20. EfficientB0 modelinin yanlış sınıflandırdığı örnek görüntüler.....	55
Şekil 5. 21. Kullanılan modellerin karşılaştırılması.....	56



SİMGELER VE KISALTMALAR LİSTESİ

GAN: Generatif Çekişmeli Ağlar

IDC: Invasive Ductal Carsinoma

TCIA: The Cancer Image Archive (Kanser Görüntü Arşivi)

WSI: Whole Slide Imaging (Tam Slayt Görüntü)

1STL: First Segmentation- based Learning

DeepML: Deep Multi-Layer Learning (Derin Çok Katmanlı Öğrenme)

VarMIL: Variety of Machine Learning

2STL: Second Segmentation-based Learning

BRCA: Breast Cancer Susceptibility

DiaL: Deep Interactive and Learning (Derin Etkileşim ve Öğrenme)

DCNN: Deep Convolutional Neural Network (Derin Evrişimsel Sinir Ağları)

CAM: Class Activation Mapping

ReLU: Rectified Linear Unit (Düzleştirilmiş Doğrusal Birim Katmanı)

ELU: Exponential Linear Unit (Üstel Lineer Birim)

SVM: Support Vector Machine (Destek Vektör Makinesi)

CNS: Central Nervous System (Merkezi Sinir Sistemi)

AUC: Area Under Curve (Eğri Altındaki Alan)

ROC: Receiver Operating Characteristic (Alıcı İşletim Karakteristiği)

QCNN: Quantum Convolutional Neural Network

LSTM: Long Short-Term Memory (Uzun Kısa Süreli Bellek)

ResNet: Residual Network (Artık Ağ)

DenseNet: Densely Connected Convolutional Network (Yoğun Bağlantılı Evrişimli Sinir Ağı)

MobileNet: Mobile Convolutional Neural Network (Taşınabilir Evrişimli Sinir Ağı)

BRCA1: Breast Cancer 1

BRCA2: Breast Cancer 2

EOC: Epiteryal Ovary Cancer

CCC: Clear Cell Carcinom

EC: Endometrioid Carcinom

HGSOC: High-Grade Serous Ovarian Cancer (Yüksek Dereceli Seröz Yumurtalık Kanseri)

LGSC: Low-Grade Serous Carcinoma (Düşük Dereceli Seröz Karsinom)

DP: Doğru Pozitif

DN: Doğru Negatif

YP: Yanlış Pozitif

YN: Yanlış Negatif

GPU: Graphics Processing Unit (Grafik İşlemci Birimi)

ILSVRC: ImageNet Large Scale Visual Recognition Challenge

ROC: Receiver Operating Characteristic (Alıcı İşlem Karakteristikleri)

RMSProp: Root Mean Square Propagation

DMNN: Deep Multi-Magnification Network

CNN: Convolution Neural Network (Evrişimsel Sinir Ağları)

DNN: Deep Neural Network (Derin Sinir Ağları)

VGG: Visual Geometry Group (Görsel Geometri Grubu)

1. GİRİŞ

Kadınlarda dünya genelinde sekizinci sık görülen kanser türü olan yumurtalık kanseri kötü huylu tümörler arasında yer alır (Sung et al., 2021). Her yıl dünya genelinde 239000 yeni yumurtalık kanseri vakası tespit ediliyor, bu da tüm kanser vakalarının %3,6'sını oluşturmaktadır. Ölümle sonuçlanan 152.000 vakaysa tüm kanser ölümlerinin %4,3'ünü oluşturuyor. Bu istatistiklere göre, yumurtalık kanseri dünya genelinde yedinci sırada yer alırken, kadınlarda kanser kaynaklı ölümlerin sekizinci en yaygın sebebi ve jinekolojik kanser ölümlerinin ikinci en yaygın sebebi konumuna geliyor (Bray et al., 2018). Hastalığın genellikle karın içinde yaygın bir şekilde ilerlemesi, yüksek ölüm oranlarına yol açmaktadır. Yumurtalık kanseri teşhisi konan kadınlar içinde, genel olarak %40'lık bir sağkalım oranı mevcuttur ve yeni tedavilerin geliştirilmesiyle birlikte bu oran artmaktadır (Jayson, Kohn, Kitchener and Ledermann, 2014). Çoğu yumurtalık kanseri epitel kökenli tümörlerdir ve genellikle beş farklı histolojik alt tipte sınıflandırılırlar. Bu alt tipler yüksek dereceli seröz, düşük dereceli seröz, açık hücreli, endometrioid ve müköz olarak adlandırılır. Epitel dışı yumurtalık kanserleri de nadiren görülür. Yumurtalık kanseri alt tipleri morfolojik ve beklenen seyir açısından farklılık gösterir ve çeşitli tedavi seçenekleri bulunur (Köbel et al., 2008).

Teknolojinin gelişmesiyle birlikte bu farklı çeşitli tedavi yöntemlerine katkı sunma amacıyla erken teşhisin yapay zeka modelleri ile yapılması da eklenmiştir. Ancak, yapay zeka modelleri yumurtalık kanseri gibi özellikle zor tespit ve teşhis edilen bir hastalıkta, mevcut patolojik eksikliğine rağmen henüz klinik uygulamaya entegre edilememiştir (Breen, Allen, Zucker, 2023). Her ne kadar klinik uygulamaya entegre edilememişse de literatürde yapay zeka modelleri ile erken teşhis üzerine bir çok çalışma bulunmaktadır.

Örneğin, çalışmada Generatif Çekişmeli Ağlar (GAN) kullanılarak, Kanser Genom Atlası'ndan beş kanser türü ve yumurtalık karsinomunun beş ana histolojik alt türü dahil olmak üzere toplamda on histolojik kanser türünün yüksek çözünürlüklü patoloji görüntüleri sentezlenerek generatif çekişmeli ağların etkinliği değerlendirilmiştir. Sonuçlar incelendiğinde gerçek ve sentetik görüntülerin histotipe göre benzer doğruluklarla sınıflandırıldığı ve sentetik görüntülerin görsel olarak gerçek görüntülerden ayırt edilemez olduğu görülmektedir. Ayrıca derin evrişimli sinir ağları farklı kanser türlerini de tanımlamak için eğitilmiş ve sentetik görüntüler, sınırlı bir eğitim setini tanımlamak için kullanıldığında ek gerçek görüntüler ile benzer özellikler göstermiştir (Levine et al., 2020).

Yapılan başka bir çalışmada yumurtalık kanserinde kullanılan platin bazlı kemoterapiye

verilen yanıtı tahmin etmek için histopatoloji ve fonksiyonel omiks bulgularını birleştiren bir algoritma geliştirilmiştir. Evrişimli sinir ağları, kanserli bölgeleri tanımlamak ve tümör derecesini sınıflandırmak amacıyla kullanılmıştır. Sonuçlar evrişimli sinir ağlarının kanserli bölgeleri ve tümör derecesini yüksek doğrulukla tanımlayabildiğini ortaya koymaktadır. Geliştirilen algoritmanın, diğer tümör türleri ve tedavi yöntemlerine adapte edilebilme potansiyeli de bulunmaktadır (Yu et al., 2020).

2020 yılında yapılan bir araştırmada, invaziv duktal karsinom (IDC) olarak bilinen meme kanserinin en sık rastlanan alt tipinin otomatik tespiti için derin transfer öğrenme yöntemi önerilmiştir. IDC tespit görevi için ResNet-50 ve DenseNet-161 gibi önceden eğitilmiş derin öğrenme modelleri kullanılmıştır. Eğitimin sonunda, önceden eğitilmiş derin ağların son katmanlarında, DenseNet-161 modeli %92,38 F1-Skoru elde ederken, ResNet-50 ise %94,11 F1skoru elde etmiştir. Her iki modelde invaziv duktal karsinomun otomatik tespiti için etkili olduğunu kanıtlamıştır (Celik, Talo, Yildirim, Karabatak and Acharya, 2020).

Bir diğer çalışmada, yumurtalık kanseri patoloji görüntüleri kullanılarak, görüntüden görüntüye tarz transferi yöntemlerinin tanısal performansı üzerinde etkileri incelenmiştir. 142 yumurtalık kanseri hastasının görüntülerini içeren kapsamlı ve kamuya açık veri seti olan The Cancer Image Archive (TCIA) kullanılarak, Inception V3 derin öğrenme modeli ile doku kesitlerindeki kanseri belirlemek için ayarlanmıştır. Çalışma tarz transferi teknolojisinin derin öğrenme modelini dijital patoloji alanında küçük görüntü setlerine nasıl genelleştirebileceğini başarıyla göstermektedir (Kavitha, Dhanapriya, Vignesh and Baskaran, 2021).

Çalışmada, yumurtalık kanseri histopatolojik tiplerinin derin öğrenme modelleri ile sınıflandırılması incelenmiştir. İki farklı kaynaktan elde edilen WSI (genişletilmiş slayt görüntüleri) kullanılmıştır. İlk veri seti iç eğitim için kullanılırken ikinci veri seti ise dış test için kullanılmıştır. Renk normalizasyonu kullanılmış ve dört farklı derin öğrenme modeli (1STL, DeepML, VarMIL ve 2STL) kullanılarak sınıflandırma yapılmıştır. En başarılı model, 1STL modeli olmuştur ve dış veri setinde %80,97'lik tam görüntü düzeyinde doğruluk oranı elde edilmiştir. Sonuçlar, yumurtalık kanseri histotiplerinin derin öğrenme modelleriyle başarılı bir şekilde sınıflandırılabilirliğini göstermektedir (Farahani et al., 2022).

Yapılan bir diğer çalışmada, yüksek dereceli yumurtalık kanseri segmentasyonu ve Breast Cancer Susceptibility (BRCA) mutasyonun tahmini için derin öğrenme tabanlı metodoloji geliştirilmiştir. İlk adımda yumurtalık kanseri segmentasyonunda Deep Multi-Magnification Network (DMNN) kullanılmıştır. Çeşitli büyütme seviyelerindeki morfolojik

özelliklerden faydalanılarak kanser bölgelerini otomatik tanımlamak için segmentasyon bölgeleri oluşturulmuştur. İkinci adımda BRCA mutasyonunun tahmini için ResNet-182 kullanılmıştır. Ayrıca manuel etiketleme sürecini azaltmak için Deep Interactive Learning (DIaL) yöntemi kullanılmıştır. Sonuç olarak bu yaklaşım, yumurtalık kanseri görüntülerindeki kanser bölgelerini otomatik olarak tanımlayarak BRCA mutasyonun tahmin etmeyi sağlamıştır (Ho et al., 2023). BRCA1/2 gen mutasyonlarının tahmin edilmesi için yapılan bir diğer çalışmada ise hesaplamalı patoloji kullanılarak bir model geliştirilmiştir. Model, toplam 664 yumurtalık kanseri hastası üzerinde test edilmiş ve %35,1'inde somatik BRCA 1/2 mutasyonu saptanmıştır. Eğitim ve test setlerinde sırasıyla 0.7 ve 0.55 ROC AUC başarısı elde edilmiştir (Nero, Boldrini, 2022).

Bir diğer çalışmada derin konvolüsyonel sinir ağının (DCNN) ultrason görüntülerinde iyi huylu, belirsiz ve kanserli yumurtalık tümörlerini doğru bir şekilde ayırt etme yeteneği incelenmiştir. 265 hastanın 279 patoloji görüntüleri kullanılarak yapılan çalışmada beş farklı DCNN mimarisi (VGG-16, GoogleNet, Resnet34, MobileNet ve DenseNet) eğitilmiş ve model performansı değerlendirilmiştir. Resnet34 modeli, üç sınıflı sınıflandırma görevinde en iyi performansı sergileyerek yüksek hassasiyet ve doğruluk değerlerine sahip olduğunu kanıtlamıştır. Sınıflandırma kararlarını görselleştirmek ve anlamak için ise Class Activation Mapping (CAM) yöntemi kullanılmıştır. Sonuçlar önerilen modelin klinik uzmanlara benzer bölgelere odaklandığını ve doğru teşhisler koyduğunu gösterirken bazı durumlarda ise yanıltıcı olabileceğini de ortaya koymuştur (Wang et al., 2021).

2021 yılında çalışmada yumurtalık kanseri ve alt tiplerinin histopatolojik görüntüler üzerinden sınıflandırılması için Derin Evrişimli Sinir Ağı (DCNN) kullanılması önerilmiştir. Alexnet modelinden ilham alınarak yeni bir DCNN mimarisi tasarlanmıştır. Tasarlanan yeni mimaride her çift evrişim katmanından sonra maksimum havuzlama katmanı eklenerek, dört tam bağlı katman eklenmiştir. ReLU yerine Exponentiak Linear Unit (ELU) kullanılarak mimari ve parametre ayarlamaları yapılmıştır. Modelin eğitiminde 24742 artırılmış görüntü kullanılmıştır ve doğruluk oranı %83,93'e yükselmiştir (K. R. Kasture, Shah and Matte, 2021).

Kılıçarslan ve diğerleri tarafından yapılan çalışmada kanser hastalıklarının teşhisi ve sınıflandırılmasında gen ifade değerlendirmesinin önemi vurgulanmıştır. Relief ve üst üste oto kodlayıcı yaklaşımlarıyla boyut azaltma, destek vektör makineleri (SVM) ve evrişimli sinir ağları (CNN) ile sınıflandırma için hibrit bir yöntem önerilmiştir. Yumurtalık kanseri, Lösemi ve Merkezi Sinir Sistemi (CNS) gen ifade analiz veri setlerinde, boyut azaltma yöntemlerinin SVM ve CNN ile sınıflandırma başarısını arttırdığı belirlenmiştir.

Yumurtalık kanseri veri setinde %98,6, Lösemi veri setinde %99,86 ve CNS veri setinde %83,95 sınıflandırma başarıları elde edilmiştir. Bu sonuçlar, kanser sınıflandırma çalışmalarında boyut azaltma tekniklerinin önemi ortaya koymaktadır (Kilicarslan, Adem, 2020).

CNN mimarisi kullanılarak yapılan çalışmada, model %94 doğruluk elde ederek yumurtalık kanserli vakaların %95,12'sini doğru bir şekilde sınıflandırdı ve sağlıklı hücrelerin %93,02'sini doğru şekilde tanımlamıştır. Sonuçlar incelendiğinde CNN tabanlı yaklaşımların yumurtalık kanserinin tahmin ve teşhisindeki önemini vurgulamaktadır (Ziyambe et al., 2023).

Yumurtalık tümörlerinin sınıflandırması için yapılan çalışmada, Inception-ResNet v2 derin öğrenme yöntemi kullanılarak sınıflandırma önerilmiştir. Önerilen yöntem özel bir veri kümesi üzerinde %97,5 doğruluk oranıyla doğrulama ve %67 test doğruluğu elde etmiştir. Ek olarak doğrulama veri setinde %92 doğrulukla çalışan bir kuantum konvolüsyonel sinir ağı (QCNN) ile test edilmiştir. Inception-ResNet v2 mimarisi, Inception ailesinin başarısını sürdürürken artıklı bağlantıların öğrenmeyi hızlandırdığını göstermektedir. Modelde Adam optimizasyonu ve Sparse Categorical Cross Entropy kaybı kullanılmıştır ve 256x256x3 boyutundaki giriş görüntüleri üzerinde 400 epok eğitim gerçekleştirilmiştir. Sonuçlar çalışmanın yumurtalık tümörlerini sınıflandırmak için etkili bir derin öğrenme yaklaşımı olduğunu göstermektedir (Kodipalli, Guha, Dasar, 2022).

Meme kanserinin teşhisi için önerilen derin öğrenme modelinin geliştirilmesine odaklanılan bu çalışmada, aşırı uyum problemi ele alınarak AlexNet-BC modeli oluşturulmuştur. Oluşturulan model öncelikle ImageNet veri kümesinde ön eğitim almakta daha sonra meme patolojisi görüntülerini sınıflandırmak için ince ayar yapmaktadır. Ayrıca softmax-çapraz entropi öğrenimindeki aşırı uyumunu azaltmak için, tahmin edilen olasılığın belli eşik değerini aştığı durumlarda çapraz entropi kaybını cezalandıran yeni bir düşük entropi çıktı cezası önerilmiştir. Farklı veri kümeleri ile yapılan deneylerde AlexNet-BC'nin diğer yöntemlerden daha iyi performans gösterdiği görülmektedir (Tang et al., 2022).

(Ghoniem et al., 2021) tarafından yapılan çalışmada yumurtalık kanserinin evresini kesin olarak tahmin etmek için çoklu-veri modalite entegrasyonlu derin öğrenme modeli önerilmiştir. Bu model, gen ve histopatoloji görüntü verilerini birleştirir ve ALO-optimized LSTM ve CNN ağları ile soyut özellikler çıkarır. Çalışma önerilen modelin yumurtalık kanseri teşhisindeki diğer dokuz model ile karşılaştırıldığında daha yüksek doğruluk ve kesinlik elde ettiğini göstererek, önerilen modelin üstünlüğünü kanıtlamaktadır.

Bir diğerk çalışma da yumurtalık kanseri sınıflandırma modeli için transfer öğrenmeye dayalı bir yaklaşım kullanır. Bu yaklaşım, önceden eğitilmiş modelleri temel olarak alır ve modeli yumurtalık kanseri histopatolojik görüntülerini sınıflandırmak için uygular. Ayrıca, veri arttırma teknikleriyle ön işleme yapar, böylece daha genelleştirebilir ve daha iyi sonuçlar verir. Kullanılan veri arttırma teknikleri modelin farklı sınıflar arasında dengeli bir şekilde öğrenmesini ve daha doğru sonuçlar elde etmesine yardımcı olmuştur. Farklı mimarilerin, ResNet-50 Efficient-B0 gibi, kullanılarak eğitilen modellerin yumurtalık kanseri görüntülerini, sınıflandırması üzerindeki etkisi değerlendirilmiştir. Üç CNN mimarisi, veri kümesi üzerinde ince ayar ile transfer öğrenme kullanılarak eğitilir ve sonuçlar karşılaştırılır.

Derin öğrenme tekniklerinin kanser hücrelerinin sınıflandırmasındaki başarısı, literatürde sıkça vurgulanmış ve bu metotların özellikle yumurtalık kanseri gibi farklı kanser türlerindeki uygulamalarına dair pek çok örnek incelenmiştir. Literatürde çoğunlukla büyük veri setlerinde genel sınıflandırma performansı üzerine yoğunlaştığı gözlemlenmektedir. Bununla birlikte, yumurtalık kanseri gibi nadir kanser türleri için özel olarak uyarlanmış bir sınıflandırma yaklaşımının yetersizliği görülmektedir. Derin öğrenme yöntemlerinin yumurtalık kanseri sınıflandırmasında kullanımına dair tespit edilen eksiklikler arasında özelleştirilmiş ve optimize edilmiş modellerin yetersizliği, mevcut veri setlerinin yetersizliği veya dengesizliği gibi faktörler bulunmaktadır. Ayrıca, mevcut yöntemlerin nadir görülen türler arasında yer alan yumurtalık kanseri gibi durumlarda sınıflandırma zorluklarına yönelik etkili bir çözüm sunamadığı gözlemlenmiştir. Genellikle, literatürde iyi veya kötü huylu olarak ikili sınıflandırma yapılmış ve çok sınıflı sınıflandırmanın sınırlı olduğu tespit edilmiştir.

Bu çalışma, yumurtalık kanseri sınıflandırmasında derin öğrenme tekniklerinin etkinliğini incelemeyi ve özellikle transfer öğrenme stratejisi ile bu alandaki boşluğu kapatmayı hedeflemektedir. Çalışmanın önemli katkılarından biri, sınırlı veri durumlarında bile etkili sonuçlar elde etmek için önceden eğitilmiş ağırlıkların transfer öğrenme yoluyla uyumlu hale getirilmesine dayanmaktadır. Bu çalışma, özgün ve özel bir yöntem kullanarak, literatürdeki bu açığı kapatmayı ve yumurtalık kanseri teşhisi ve sınıflandırması alanında yenilikçi bir yaklaşım sunmayı hedeflemektedir.

Tezin geri kalan bölümünde yumurtalık kanseri, yumurtalık kanseri sınıflandırmasında görüntü işleme ve yapay zeka tekniklerinin kullanımı, materyal ve yöntem, bulgular ve değerlendirmeleri sonuç ve öneriler bölümlerine yer verilmiştir.

2. YUMURTALIK KANSERİ


Yumurtalık kanseri, epitel hücrelerinden kaynaklanan ve kadın üreme sistemini etkileyen en ölümcül kanser türlerinden biridir. Vakaların çoğunda belirti görülmediği için genellikle ileri aşamalarda teşhis edilir ve bu durum tedavi seçeneklerini sınırlamaktadır. Yapılan bir araştırmada, bu kanserin hücrel ve moleküler çeşitliliğini ortaya koymuş ve bu durum tedavi yöntemlerinin karmaşıklığını ortaya koymuştur (David DL Bowtell, 2010). Araştırmalar, BRCA1 ve BRCA2 gibi gen mutasyonlarının yumurtalık kanseri riskini önemli ölçüde artırdığını ortaya koymaktadır (Norquist, Harrell, Brady, 2016). Yumurtalık kanseri tanısında ve tedavisinde genetik testlerin giderek artan önemi, hastalığın erken teşhis edilmesi ve tedavinin planlanması açısından kritik rol oynamaktadır (J. Zhang et al., 2022).

2.1 Yumurtalık Tümörleri

Yumurtalık kanseri, farklı alt histolojik alt tiplere ayrılabilen ve her birinin farklı tanımlanabilir risk faktörleri, hücrel kökenleri, moleküler yapıları, klinik özellikleri ve tedavi seçenekleri olan bir dizi alt kategoriye ayrılabilir. Bu histolojik alt tipler, yumurtalık kanserlerinin yaklaşık %90'ını oluşturan epitel kanserlerini içerir (Oswald and Gourley, 2015). Alt bölümlerde bu çalışmada sınıflandırma yapılan tümör türleri açıklanmaktadır.

2.1.1 Epitel Yumurtalık Tümörleri

Epiteryal yumurtalık kanseri (EOC), histolojik olarak yüksek dereceli seröz, düşük dereceli seröz, açık hücreli, endometrioid ve müköz yumurtalık kanseri olmak üzere beş ana alt tipte sınıflandırılır. Bu alt tiplerin hepsi çeşitli klinik belirtiler ve tedaviye verilen farklı yanıtlar gösterir. Tümörün içsel biyolojisi, farklı davranışlar sergiler ve bu durum, hastalığın seyrini ve sonucu etkiler (Lheureux, Braunstein and Oza, 2019). Yumurtalık epitel tümörleri geniş çapta 2 ana tür hastalığı ayırabilir. Tip I yumurtalık karsinomu, berrak hücreli karsinom (clear cell carcinoma- CCC), endometrioid karsinom (endometrioid carcinoma – EC), müsinöz karsinom ve düşük dereceli karsinomdan oluşurken, Tip II yumurtalık karsinomu genellikle yüksek dereceli karsinomdan oluşur ve bu en yaygın ve ölümcül yumurtalık kanseri türüdür (Kurman and Pathology, 2010). Şekil 2.1'deki görüntü, yumurtalık karsinomlarının ana histolojik varyantları gösterilmektedir.



Şekil 2.1. Yumurtalık karsinomlarının başlıca histolojik alt tipleri

Kaynak: (Kurman and Pathology, 2010)

2.1.1.1 Yüksek Dereceli Seröz Karsinom

Yüksek dereceli seröz yumurtalık kanseri (HGSOC), yumurtalık kanseri ölümlerinin %70-%80'ini oluşturmalarına rağmen, genel sağkalım açısından önemli bir değişiklik gözlenmemiştir (David D. Bowtell et al., 2015).

2.1.1.2 Endometrioid Karsinom

Yumurtalık epitel kanser (EC), endometriyal kistlerle sıkça ilişkilendirilen bir alt tiptir. Yumurtalık epitelial kanserlerinin çoğu, yumurtalık veya pelvik bölgedeki dışında rahme ait dokunun dışında büyümesi ile ilişkilidir ve bazı durumlarda rahim içi kanserle birlikte bulunabilir. Yumurtalık Epitelial Kanserler genellikle iyi belirgin veya düşük derecelidir ve rahimdeki yumurtalık epitelial kanserlerine benzer özellikler gösterir. Bu kanserlerin çoğu, endometriyal kistlerin içinde katı tümörler olarak büyür. Sonuç olarak yumurtalık epitel kanserler, çoğunlukla endometriyal kistlerle ilişkilidir ve genellikle düşük derecelidir; rahimdeki benzer kanserler ile ortak özellikler taşırlar (Maeda, Pathology, ve 2013).

2.1.1.3 Berrak Hücreli Karsinom

Berrak hücreli karsinom (BHKC), yumurtalık kanserinin az rastlanan, fakat hızlı ilerleyen agresif bir türüdür. Bu tümörler tipik olarak yüksek seviyede nükleer anormallik ve eozinofilik sitoplazmalı hücrelerin varlığını sürdürme eğilimindedirler (Young, 2014).

Berrak hücreli karsinom, sıklıkla endometriozis ile bağlantılıdır ve bu kanser türü en

sık menopoz sonrası dönemdeki kadınlarda görülür (McCluggage, 2008).

Klinik olarak, berrak hücreleri karsinom diğer yumurtalık kanseri türlerine göre kıyasla daha kötü bir seyir izler. Çoğu berrak hücreleri karsinom hastası, teşhis edildiklerinde genellikle hastalık erken evrelerdedir, ancak tümörün agresif yapısı nedeniyle hastalık ilerleyebilir ve tedaviye karşı direnç gösterebilir (Sugiyama, Kamura, 2000).

2.1.1.4 Düşük Dereceli Seröz Karsinom

Düşük dereceli seröz karsinom (LGSC), yumurtalık kanserlerinin ender görülen bir alt tipidir ve yüksek dereceli seröz karsinomdan (HGSC) ayrılarak daha yavaş ilerleyen bir seyir izler. Seröz karsinomun klinik ve moleküler özellikleri genellikle diğer yumurtalık kanseri tiplerinden ayrılır ve bu durum, tedavi ve beklenti üzerinde önemli etkilere sahip olabilir (Slomovitz et al., 2020). Epidemiyolojik olarak, düşük dereceli karsinom, yumurtalık kanserlerinin %10 ila %15'ini temsil eder ve sıklıkla 40 ile 60 yaşları arasındaki genç kadınlarda ortaya çıkar (Gershenson, 2016).

2.1.1.5 Müköz Karsinom

Müköz karsinomlar, yumurtalık yüzeyindeki hücrelerden kaynaklanır ve yumurtalık kanserlerinin bir alt tipidir. Bu tümörlerin çoğu metastatiktir, yani başka bir yerden yayılmıştır, ancak bazıları doğrudan yumurtalıkta başlar. Müköz karsinomlar, müköz hücrelerden oluşan tümörlerdir ve genellikle yumurtalık kanserlerinin %6 ila %25'ini oluşturmaktadır (Seidman vd.,2003).


3. YUMURTALIK KANSERİ SINIFLANDIRMASINDA GÖRÜNTÜ İŞLEME VE YAPAY ZEKÂ TEKNİKLERİNİN KULLANIMI

Yapay zekâ ve görüntü işleme teknolojilerindeki gelişmeler, medikal görüntülerden önemli veriler elde etmek için yeni imkânlar sunmaktadır. Bu çalışmada yumurtalık kanserinin sınıflandırılması için yapay zekâ ve görüntü işleme yöntemlerinin potansiyeli hakkında araştırmalar yapılmıştır. Bu süreçte histopatolojik görüntülerden elde edilen verilerin analizi için görüntü işleme süreçleriyle ilgili adımlar gerçekleştirilmektedir. Bu çalışmanın hedefi, yumurtalık kanseri teşhisinde yapay zekâ destekli sınıflandırma sistemlerinin etkinliğini değerlendirmek ve katkı sunmaktır. Çalışmada yumurtalık kanserinin erken teşhisine ve etkili tedavi yöntemlerinin geliştirilmesine yardımcı olmayı amaçlanmıştır.

3.1 Yapay Sinir Ağları

Yapay sinir ağları, insan beyninin özelliklerini taklit eden algoritmaları barındırır; bu özellik, yeni bilgi oluşturma ve öğrenme yoluyla keşfetme süresini içerir. Yapay sinir ağları, biyolojik sinir ağlarının yapısını ve işlevlerini taklit eden yapay ağlardır (G. Zhang, Patuwo, Forecasting and 1998).

Çok katmanlı ileri beslemeli yapay sinir ağlarının temel yapısı Şekil 3.1.'de verilmiştir. Bu yapı giriş, gizli ve çıkış katmanlarından oluşan çok katmanlı bir yapıya sahiptir. Her katmandaki nöronlar birbirlerine ağırlıklar aracılığıyla bağlanır. Ancak aynı katmandaki nöronlar arasında bağlantı bulunmamaktadır (Egrioglu, Aladag, Yolcu, 2009).



Şekil 3.1. Çok Katmanlı İleri Beslemeli Yapay Sinir Ağı Modeli

Kaynak: (Kızrak, M. A., & Bolat, 2018)

Geri yayılım algoritması, Yapay sinir ağlarının gerçek değerler ile çıkış değerleri arasındaki farkı kullanarak ağırlıkların güncellendiği yaygın bir öğrenme algoritmasıdır.

Algoritmaların istenilen çıkışlara ne kadar etkili şekilde ulaştığını belirleyen faktör öğrenme parametresidir. Bu parametre, algoritmanın işleyişine bağlı olarak sabit bir değer belirlenebileceği gibi dinamik olarak da güncellenebilir. Öğrenme parametresi kadar kritik bir role sahip olan aktivasyon fonksiyonu, ağıın başarı oranını ve genel performansını etkileyen önemli bir değişkendir. Bu fonksiyon, yapay sinir ağının giriş ve çıkış arasında doğrusal olmayan bir ilişki kurmasını sağlar. Ağıın başarımı, doğru aktivasyon fonksiyonunun seçimine bağlıdır. Bu fonksiyon, doğrusal, çift kutuplu veya tek kutuplu olabilir. Doğrusal olmayan aktivasyon fonksiyonlarında, eğim parametresi belirlenmelidir, çünkü bu parametre, hedeflenen çıkış değerlerine ulaşmada kritik bir rol oynar (Egrioglu et al., 2009).


3.2 Derin Öğrenme

Derin öğrenme, yapay sinir ağlarının kullanımıyla büyük miktarda veri gerektiren karmaşık sorunları ele alan makine öğreniminin bir alt kümesidir. Bu ağlar birbirine bağlı düğümlerin çok katmanlı yapılarını içerir ve verilerdeki desenleri ve özellikleri geri yayılım olarak adlandırılan süreçle ayırt etme yeteneğine sahiptir. Geleneksel makine öğrenimi yöntemlerinin başarılı olmadığı ses ve görüntü tanıma, doğal dil işleme gibi alanlarda derin öğrenme algoritmaları oldukça başarılıdır (LeCun, Bengio, Nature and 2015).

Son dönemde, derin öğrenme makine öğrenimi sahasında öncü bir strateji olarak ortaya çıktı ve makine öğrenimi topluluğu tarafından standartlaştırıldı. Bu evrensel kabul, derin öğrenmenin makine öğrenimi alanında sıkça kullanılan bir hesaplama yöntemi haline gelmesini sağladı (Alzubaidi et al., 2021).

3.3 Evrişimli Sinir Ağları


Evrişimli sinir ağları (CNN'ler), bilgisayar görüşü ve görüntü tanıma uygulamalarında oldukça yaygın kullanılan sinir ağı türlerinden biridir ve birçok uygulama etkilidirler. Özellikle görüntü tanıma ve sınıflandırma gibi alanlarda etkili performans sergilerler. Tipik olarak CNN'ler bir dizi evrişim katmanı ile başlar ve bunları bir veya daha fazla tam bağlantılı katman takip eder (Platania et al., 2017). Genellikle, bir CNN mimarisi evrişim katmanları, aktivasyon katmanı, havuzlama katmanı ve tam bağlantılı katman içerir. Evrişim katmanları, belirli özellikleri tespit etmek için giriş görüntülerini işleyen evrişim çekirdeklerinden oluşur. Ağıın başlangıcında temel özellikler, örneğin kenarlar ve şekiller, ilerleyen katmanlarda giderek daha karmaşık ve özelleşmiş hale gelir. Şekil 3.2'de evrişimli sinir ağları mimarisi görülmektedir. Evrişim çekirdeklerinin parametreleri, giriş görüntüsünün boyutunu ve ağıın yapısı dikkate alınarak ayarlanmalı ve optimize edilmelidir (Zhou, Zhang, Liu, 2019).



Şekil 3. 2. Evrişimli Sinir Ağları Mimarisi

Aktivasyon katmanı, CNN modellerindeki önemli bir bileşendir. Bu katman, önceki konvolüsyon veya tam bağlantılı katmanların çıktılarını doğrusal olmayan bir şekilde ifade etmek için aktivasyon fonksiyonlarını kullanır. Bu fonksiyonlar arasında Sigmoid, Tanh ve ReLU gibi seçenekler bulunmaktadır. Bu fonksiyonlar, ağıın çıktılarını daha karmaşık ve geniş bir alanda ifade etmek için kullanılır, bu da ağıın daha karmaşık ilişkileri öğrenerek daha etkili bir şekilde performans göstermesini sağlar. Bu aktivasyon fonksiyonlarının yanı sıra, ağıın işleyişini optimize etmek için havuzlama katmanları da kullanılır.

Havuzlama katmanı, çıkarılan özellik haritalarının uzamsal boyutlarını ve ağı parametrelerinin sayısını azaltmak için ortalama havuzlama, toplam havuzlama veya maksimum havuzlama gibi doğrusal olmayan sayısal işlemleri gerçekleştirir (Paoletti, Haut, Plaza, Photogrammetry and 2019).



Şekil 3. 3. Maksimum Havuzlama İşlemi

Kaynak: (Kizrak, M. A., & Bolat, 2018)

3.4 Transfer Öğrenimi


Eğitim transferi, derin mimarilerde, önceden eğitilmiş bir yapay sinir ağı modelinin son katmanlarının yeni probleme uygun hale getirilmesiyle sağlanır. Bu yaklaşım, her yeni problem

için sıfırdan eğitime başlamak yerine, önceden öğrenilmiş ağırlık parametre değerlerinin yeniden kullanılmasını sağlar. Temel amacı, ilk katmanlarının genellikle her görüntü tanıma problemi için ortak olan düşük seviyeli özellikler öğrenmesidir. Eğitim transferinin etkinliği, mimarinin detaylarına bağlıdır. Bu nedenle katman seçimi ve başlangıç değerlerinin belirlenmesi bu aşamada önem arz etmektedir (Deniz, Bahçeşehir, 2018).

Eğitimde önceden belirlenmiş ağırlıkların kullanılması, süreç, hızlandırarak daha verimli bir eğitim sağlar. Hazır bir model olan ImageNet görüntüleri kullanılarak önceden eğitilmiş modele basit katmanlar eklenerek, daha az veriyle daha yüksek başarı elde edilebilmektedir (Tezcan, Kiras , 2022).

3.4.1 Residual Neural Network (ResNet)

Şekil 3.4’de mimarisi verilen ResNet, derin konvolüsyonel sinir ağlarının eğitim sürecindeki zorlukları, aşırı öğrenme ve doğruluk kaybı problemlerini çözmeyi hedefleyen yenilikçi bir yaklaşımdır. Karmaşık görevlerin üstesinden gelmeyi kolaylaştıran ve tespit doğruluğunu arttıran ResNet50 mimarisi, 50 katmanlı artık ağ yapısına sahiptir (Mukti and On, 2019).



Şekil 3. 4. Resnet-50 Mimarisi

Kaynak: (Mukti and On, 2019)

Şekil 3.4’te gözlemlenebildiği üzere her grup kendine özgü bir renkle vurgulanır ve kıvrımlı hatlar, geçiş bağlantılarını ifade eder. Mimari öncelikle 64 çekirdekli evrişim katmanı


ile başlar ve buna 7x7 boyutunda bir alana sahiptir. Ardından bu evrişim katmanının çıkışı üzerine 3x3 boyutunda maksimum havuzlama katmanı uygulanır. Sonrasında farklı renklerle belirginleştirilmiş benzer katmanlar içiren bloklar bulunmaktadır. Resnet50'nin toplam parametre sayısı yaklaşık 23 milyon olarak belirlenmiştir. Bu mimari derin öğrenme alanında son derece önemlidir ve birçok alanda başarılı bir şekilde kullanılmaktadır (Shabbir, Ali, Ahmed, 2021).

3.4.2 EfficientNet

EfficientNet modeli, yaklaşık 66 milyon parametre ile ImageNet sınıflandırma probleminde %84,4 doğruluk elde ederek, CNN modelleri arasında önemli bir başarı elde etmiştir. EfficientNet serisi, B0'dan B7'ye kadar olan 8 modele sahiptir ve model numarası artması ile parametre sayısı nispeten sabit kalırken, doğruluk önemli ölçüde yükselmektedir. Ek olarak, EfficientNet mimarisi, Rektifiye Doğrusal Birim (ReLU) aktivasyon fonksiyonu kullanan CNN modellerinden farklı olarak Swish aktivasyon fonksiyonunu kullanmaktadır (Atila, Uçar, Akyol, 2021)(Tan and Le, 2019).

EfficientNet, ağır boyutunu ölçeklendirmek için bir dizi katsayı kullanan bir CNN mimarisidir. Bu sayede ağır genişliği, derinliği ve çözünürlüğü homojen şekilde ölçeklendirilir. Bu yaklaşım her boyut için optimal ölçekleme katsayılarını tespit etmek için kullanılabilir (Sathwik et al., 2023).

EfficientNet-B0, ImageNet veri setindeki 1,2 milyon görüntüyle, temel model olmasına rağmen, son teknoloji doğruluğunu yakalar. Bu başarı, yaklaşık 5,3 milyon parametreyle elde edilirken, önceki en iyi modele kıyasla 8,4 kat daha küçük ve 6 kat daha hızlı yapıya sahiptir. Ek olarak, ImageNet veri setindeki önceden eğitilmiş EfficientNet-B0 modeli çeşitli görüntü sınıflandırma görevlerine yönelik ince ayarlar yapabilmektedir. Mimarinin katman bazındaki detayları Şekil 3.7'de sunulmuştur (Bodapati, Feroz, Yarra, Chowdary and Sekhar, 2023).



Şekil 3. 5. Efficient-B0 Genel Mimarisi

Kaynak:(Tasya, Sa'idah, 2022)


3.4.3 Inception-V3

Google tarafından geliştirilen Inception mimarisinin bir çeşidi olan Inception-V3, 2014'teki ImageNet Large Scale Visual Recognition Challenge (ILSVRC) sırasında tanıtılmıştır. Bu model derin öğrenme ve görüntü tanıma alanında kayda değer başarılar elde etmiştir. Inception-V3 mimarisinin ana hedefi, daha derin ve geniş ağlar oluştururken hesaplama verimliliğini arttırmak ve parametre sayısını azaltmaktır. Model bu amaca ulaşmak için Inception modüllerini kullanır; bu modüller, çeşitli özellikleri aynı anda çıkarmak için çeşitli çekirdek boyutlarına sahiptir (Szegedy, Vanhoucke, 2016). Bu modüller, farklı konvolüsyon katmanlarını birleştirerek, ağı daha çeşitli bir özellik yelpazesini yakalamasına imkan tanır (Ioffe and Machine, 2015).

Inception-V3'teki Inception modülleri, farklı konvolüsyon katmanlarını eş zamanlı olarak kullanarak, çeşitli özellikleri çıkarmaktadır. Örneğin, bir Inception modülü içinde 1x1, 3x3 ve 5x5 konvolüsyon çekirdekleri bir arada çalıştırılır ve bu çekirdeklerin farklı boyuttaki çıktıları birleştirilir.

Modelin mimarisinde, ayrıştırılmış konvolüsyon katmanları önemli bir rol oynar. Özellikle, büyük çekirdek boyutları olan 7x7 veya 5x5, daha küçük çekirdeklerin ardışık olarak uygulanmasıyla parçalanır. Bu yaklaşım hesaplama maliyetini azaltırken, modelin derinliğini arttırarak daha karmaşık özelliklerin çıkarılmasını sağlar (Szegedy et al., 2016). Modelin

mimarisinin ayrıntıları Şekil 3.8’de sunulmuştur.



Şekil 3. 6. Inception-V3 Mimarisi

Kaynak : (Tian, Daigle, 2018)


Eğitim aşamasında, Batch Normalization ve RMSProp optimizasyonu gibi teknikler sıkça kullanılır. Batch Normalization, her minibatch üzerinde normalizasyon işlemi gerçekleştirerek eğitim sürecini hızlandırır ve modelin genel performansını artırır. RMSProp optimizasyonu ise, adaptif öğrenme oranları kullanarak modelin daha hızlı ve daha istikrarlı bir şekilde öğrenmesini sağlar (Szegedy et al., 2016).

Inception-V3, derinliği artıran ve kaybolan gradyan problemini hafifleten "Yardımcı Sınıflandırıcılar" gibi ek bileşenleri içerir. Bu ek sınıflandırıcılar, eğitim sırasında ana ağın yan dalları olarak işlev görür ve modelin daha hızlı öğrenmesine katkıda bulunarak toplam kayıp fonksiyonunu iyileştirir (Ioffe and Machine, 2015).

3.4.4 MobileNet-V2

MobileNetV2, Google tarafından geliştirilen, düşük hesaplama gücüne sahip platformlarda etkili derin öğrenme modellerini çalıştırmayı hedefleyen bir sinir ağı mimarisidir. Bu model, MobileNetV1'e yapılan belirgin iyileştirmelerle dikkat çekmekte olup, özellikle görüntü sınıflandırma, nesne tanıma ve benzeri görevlerde etkili performans sergilemektedir. MobileNetV2'nin temel gelişmelerinden biri, "inverted residuals" ve "linear bottlenecks" olarak adlandırılan iki ana bileşenden oluşmaktadır. Inverted residuals, standart residual bağlantıların aksine, düşük boyutlu özellik haritalarını yüksek boyutlu özellik haritalarına dönüştürerek işlem yapar ve daha sonra bunları tekrar düşük boyutlu hale getirir. Bu yaklaşım, hesaplama

verimliliğini artırır ve modelin derinliğini korurken parametre sayısını azaltır. Linear bottlenecks ise, aktivasyon fonksiyonlarının uygulanmadığı, düşük boyutlu ve lineer özellik haritalarını kullanarak bilgi kaybını en aza indirir, böylece modelin öğrenme kapasitesini artırır (Sandler, Howard, Zhu, Zhmoginov and Chen, 2018). Bu paragrafta belirtilen özellikleri vurgulamak amacıyla, Şekil 3.9'da MobileNetV2'nin mimarisini açıklar.



Şekil 3. 7. MobileNetV2 Mimarisi
Kaynak:(Talahua, Buele, Calvopiña, 2021)

MobileNetV2, hesaplama maliyetlerini düşürmek amacıyla derinlik ayrımı yapılandırılmalı konvolüsyonları kullanır. Bu yöntem, standart konvolüsyon işlemlerini iki aşamada gerçekleştirir: derinlik ayrımı yapılandırılmalı konvolüsyon ve noktasal konvolüsyon. Bu iki aşamalı süreç, geleneksel konvolüsyonlara kıyasla daha az hesaplama gerektirir ve modelin daha hızlı çalışmasını sağlar. Eğitim sürecinde, MobileNetV2'de genellikle "ReLU6" aktivasyon fonksiyonu kullanılır, çünkü düşük bitli hesaplamalarda daha stabil ve verimli sonuçlar elde edilmesini sağlar. Ayrıca, modelin farklı cihazlarda ve uygulamalarda kullanılabilmesi için çeşitli genişlik ve çözünürlük çarpanları sunulur. Bu çarpanlar, modelin karmaşıklığını ve hesaplama gereksinimlerini ayarlayarak farklı performans gereksinimlerine uygun hale getirilmesini sağlar (Howard et al., 2017).

3.4.5 DenseNet121

DenseNet121, her katmanın önceki tüm katmanların çıktısını girdi olarak aldığı yoğun bağlantılı bloklar kullanılarak oluşturulmuş bir derin öğrenme modeli mimarisidir. Bu mimari, her katmanın girdi olarak önceki tüm katmanların çıktılarını kabul etmesi özelliğiyle tanınır. Bu, diğer yaygın mimarilere kıyasla, katmanlar arasında daha yoğun bir bağlantı kurar.

Bu yoğun bağlantılar, eğitim sürecini optimize etmek için bilgi akışını ve gradyan yayılımını geliştirir. Yoğun bağlantılar, modelin parametre verimliliğini artırır ve derin katmanlarda gradyanların zayıflaması sorununu azaltır (Huang, Liu, 2017).


DenseNet121'de kullanılan optimizasyon teknikleri, modelin eğitim sürecini hızlandırır ve etkinleştirir. Örneğin, mini-batch gradient descent ve veri artırma gibi yöntemler, modelin genelleme yeteneğini artırarak aşırı uyum riskini azaltır (Krizhevsky, Sutskever, 2017). DenseNet121, çeşitli görüntü tanıma ve sınıflandırma görevlerinde belirgin başarı göstererek, modern derin öğrenme uygulamaları için önemli bir araç olmuştur (Huang et al., 2017).




4. MATERYAL VE YÖNTEM

Bu çalışmada, transfer öğrenme yöntemleri kullanılarak yumurtalık kanseri sınıflandırması gerçekleştirildi. Çalışmada farklı yumurtalık kanseri alt türlerini içeren beş farklı (Temiz hücreli, Endometrioid, Musinöz, Kanser olmayan, Seröz) sınıfı olan bir görüntü veri seti kullanıldı (K. Kasture, 2021). Yapılan çalışmada yumurtalık kanseri sınıflandırması için önceden eğitilmiş beş farklı transfer öğrenme modeli (Resnet50, EfficientB0, InceptionV3, MobileNetV2, DenseNet121) kullanılarak eğitimler gerçekleştirilmiştir. Her modelde aynı parametreler kullanarak eğitimler gerçekleştirilmiş; eğitim, doğrulama ve test verileri ImageDataGenerator ile hazırlanmış ve ilgili mimarilerin son katmanları eğitilebilir hale getirilmiştir. Sonrasında tüm modellerde, ince ayar (fine-tuning) yapılarak son katmanlar serbest bırakılmış, eğitimlerde Adam optimizasyon ve çok sınıflı çapraz entropi (categorical crossentropy) kayıp fonksiyonu kullanılmıştır. Sınıf ağırlıkları hesaplanarak dengesiz veri setlerine karşı direnç sağlanmış ve eğitim süreci erken durdurma, model kontrol noktası ve öğrenme oranı azaltma gibi callback fonksiyonları ile optimize edilmiştir. Eğitim ilerledikçe öğrenme oranını dinamik olarak azaltmak için de ReduceLROnPlateau stratejisi uygulanmıştır. Son olarak, eğitilmiş modeller doğrulama ve test verileri üzerinde değerlendirilmiştir. Model performansları, doğruluk, keskinlik, duyarlılık, F1-skorları değerlendirilmiştir. Ayrıca, karmaşıklık matrisi ve sınıflandırma raporu ile analiz yapılmıştır. Çalışmada, Python 3 programlama dili kullanılarak Google Colab üzerinde 25 GB RAM kapasiteli ve T4 GPU ile çalıştırılmıştır. Geliştirilen kod, Google Compute Engine altyapısı üzerine inşa edilmiştir. Geliştirilen modelin temel işleyişini gösteren akış diyagramı Şekil 4.1’de verilmiştir.

Şekil 4.1’de gözlemlenebildiği üzere modellerin değerlendirmeleri üç farklı şekilde yapılmıştır. İlk olarak, modeller veri setinde herhangi bir arttırma yapılmadan kıyaslanmıştır. İkinci olarak ise veri setinde arttırma teknikleri uygulanmış ve elde edilen arttırılmış veri seti üzerinden karşılaştırılarak değerlendirilmiştir. Son olarak modelleri artırılmış veri seti kullanılarak ve ince ayar işlemi eklenerek eğitilmiştir ve kıyaslanmıştır. Önerilen ince ayarlı modelin akıl diyagramı şekil 4.2’de sunulmaktadır.



Şekil 4. 1. Önerilen Model Akış Diyagramı



Şekil 4. 2. İnce Ayarlı Tasarım Akış Diyagramı

Materyal ve yöntem bölümünün devamında veri seti, modellerin eğitimi sırasında kullanılan yöntemler ve model değerlendirme metrikleri ile ilgili detaylı bilgiler sunulmaktadır.


4.1 Veri Seti

Çalışmada kullanılan veri seti, Yumurtalık kanseri ve alt türleri üzerine odaklanan Kasture ve arkadaşlarının çalışmasından elde edilen veri setidir (K. R. Kasture, Shah, et al., 2021). Veri seti oluşturulurken Pune, Hindistan'daki Smt. Kashibai Navale Tıp Koleji ve Genel Hastanesindeki 42 hastadan elde edilen toplam 85 kanser olmayan görüntünün incelenmesiyle, kanser dışı durumların çeşitli klinik örneklerini içeren geniş bir veri seti oluşturulmaya başlanmıştır. Ancak, bu tiplerde hastaların az olması nedeniyle Seröz kanser tipi dışındaki yumurtalık kanseri alt tiplerine ait histopatoloji görüntülerinin elde edilmesinde zorlanılmıştır.

Bu sebeple, deneyimli patologlar, hastalardan numuneler alıp slaytları hazırlamış ve bu süreçte görüntüleri çeşitlendirerek ve arttırarak elde etmişlerdir. Görüntüler, Leica ICC50 mikroskop kamerası ile yakalanarak, hücre örneklerinin laboratuvar ortamında hazırlanması ve boyanması işlemleri gerçekleştirilmiştir. Elde edilen RGB görüntüler, her biri 224x224x3 boyutlarında ve JPG formatında homojen bir biçimde yeniden boyutlandırılmıştır (K. R. Kasture, Sayankar and Matte, 2021). Elde edilen histopatolojik görüntüler öğrenme süreci, tahminlerin yapılması ve derinlemesine analizler için kullanılmıştır.


4.2 Veri Önleme ve Veri Arttırma

Bu çalışma, beş farklı sınıfa ayrılmış olan toplam 498 görüntü içeren bir veri seti üzerinde gerçekleştirilmiştir. Sınıflar şunlardır: Clear_Cell, Endometri, Mucinous, Non_Cancerous ve Serous. Her sınıf 100 görüntüden oluşurken, Endometri sınıfı 98 görüntü içermektedir. Veri arttırma işlemi yapıldıktan ve veri seti bölündükten sonra, mimariler train veri seti için 16293, doğrulama için 1046 ve test için 2091 görüntü kullanmaktadır. Eğitim oranı %83,85, doğrulama oranı %5,38 ve test oranı %10,76 olarak belirlenmiştir. Toplamda, veri setinde 19430 görüntü bulunmaktadır. Veri setinden örnek görüntüler Şekil 4.3'te gösterilmektedir.



Şekil 4. 3. Ovarian Cancer & Subtypes veri setinden örnek histopatolojik görüntüler

Çalışmada kullanılan veri setinin modelin daha başarılı bir şekilde eğitilmesi ve veri çeşitliliğin artırılması amacıyla veri arttırma teknikleri uygulanmıştır. Mevcut veri setindeki örnekler üzerine döndürme, kaydırma, yansıtma ve parlaklık ayarları dönüşümleri uygulanarak görüntülerin farklı açılardan incelenmesi, konumlarının değiştirilmesi ve parlaklık seviyelerinde değişikliklerle veri çeşitliliği sağlanmıştır. Bu işlemler, modelin daha geniş bir perspektiften öğrenmesine, aşırı uyumluluğun azaltılmasına ve çeşitli koşullara uyum sağlamasına yardımcı olmuştur. Kullanılan arttırma teknikleri sonucu elde edilen örnek görüntüler Şekil 4.4 'te sunulmaktadır.



Şekil 4. 4. Veri arttırma teknikleri sonrasında elde edilen örnek görüntüler

4.3 Modellerin Eğitimleri Sırasında Kullanılan Yöntemler

Bu bölümde modellerin eğitimi sırasında izlenen stratejiler ve kullanılan parametreler detaylandırılmıştır. Model eğitimi sırasında kullanılan stratejiler, modelin performansını arttırmak ve aşırı uyumu engellemeyi amaçlar. Bu stratejilerin uygulanmasıyla, modelin gerçek dünya verileri üzerinde daha iyi genelleme yapması ve daha tutarlı performans sergilemesi hedeflenir.

4.3.1 Fine-Tuning (İnce ayar)

İnce ayar aşaması, modelin performansını arttırmayı hedefler ve modelin belirli veri örneklerini doğru bir şekilde yansıtabilmesi için parametrelerin son derece hassas ayarlanması

gerektiğini kabul eder. Bu süreç, mevcut modelin veya belirli kısmının esneklik kazandırılmasını içerir. Yeniden eğitim sırasında, modelin veya belirli bir bölümün serbest bırakılmasıyla birlikte, yeni veriler kullanılır ve düşük öğrenme oranı tercih edilir. Bu işlem, mevcut ağırlıkların ince ayarlanmasına imkan sağlar ve modelin belirli gözlemlere daha iyi uyum sağlamasına yardımcı olur, böylece daha hassas ve doğru tahminler yapması amaçlanır (Vrbančić and Access, 2020).

Bu çalışma kapsamında, ince ayar işlemi sırasında, ResNet-50, EfficientB0, InceptionV3, MobileNetV2 ve DenseNet-121 gibi farklı modellerin son 4 katmanını eğitilebilir hale getirilmiştir. Bu modelin önceden öğrenilmiş genel özelliklerini korumak amacıyla daha önceki katmanların dondurulduğu anlamına gelir. Yani eğitim sırasında bu katmanların ağırlıkları güncellenmez, sadece son 4 katman yeni görev için özelleştirilmiş özellikleri öğrenmek üzere eğitilir.

Bu işlem, transfer öğrenme yöntemlerinden biri olan ince ayar yaklaşımının uygulanmasıyla gerçekleştirilmiştir. Bu yaklaşımın temel amacı, modelin son katmanlarında yapılan özelleştirmeler ile yeni görev gereksinimlerine daha iyi uyum sağlamaktır. Ayrıca, farklı mimariler üzerinde tutarlı bir yaklaşım sunularak genel performansın artırılması ve belirli modeller için optimize edilmiş modeller elde edilmesi hedeflenmektedir. Bu sayede, önceden eğitilmiş modellerin sağladığı genel özelliklerin korunmasıyla birlikte, belirli bir görev için özelleştirilmiş ve optimize edilmiş modeller elde edilerek, daha etkili sonuçlar elde edilmesi amaçlanmaktadır.

4.3.2 Kaybolma ve Erken Durdurma (Dropout, EarlyStopping)

Erken durdurma (early stopping), modelin aşırı öğrenmesini (overfitting) engellemek ve hesaplama kaynaklarını verimli kullanmak için kullanılan bir tekniktir. Bu yöntem, modelin doğrulama veri setindeki performansı artmadığında eğitim sürecini durdurur. Bu yaklaşımın temeli, belirli bir noktadan sonra eğitime devam etmenin modelin genelleme yeteneğin, geliştirmek yerine, modelin eğitim verilerindeki rastgele hataları ve anlamsız örüntüleri öğrenmesine neden olacağı düşüncesidir (Liang et al., 2021).

Çalışmada erken durdurma için sabır (patience) parametresi 10 olarak ayarlanmıştır. Bu doğrulama doğruluğu 10 ardışık epoch boyunca iyileşme olmazsa eğitim sürecinin durdurulacağı anlamına gelmektedir. Bu parametrenin doğru ayarlanması kritiktir; düşük bir sabır değeri eğitimi erken durdurabilirken, çok yüksek seçilmesi durumunda ise aşırı öğrenmeyi engellemeyebilir.

Erken durdurma gibi, dropout da aşırı öğrenmeyi engellemek modelin genelleme yeteneğini arttırmak amacıyla kullanılan farklı düzenlenme stratejileridir. Bu strateji, eğitim sürecinde rastgele olarak belirli oranda nöronları devre dışı bırakarak, sinir ağlarında kullanılır. Bu şekilde, ağın herhangi bir nörona aşırı bağımlı olmasını engelleyerek, ağın daha dengeli özellikler geliştirmesine yardımcı olur (Srivastava, Hinton, ... and 2014).

Dropout oranı, devre dışı bırakılacak nöronların yüzdesi olarak ifade edilen kritik bir parametredir. Yapılan çalışmada dropout katmanları için dropout oranı 0,5 olarak ayarlanmıştır. Bu oran her eğitim adımında nöronların yarısının rastgele devre dışı bırakıldığı anlamına gelir. Bu oran, genellikle tercih edilen ve çeşitli uygulamalarda etkili olduğu gösterilen bir değerdir.

4.3.3 Sınıf Ağırlıkları (Class Weights)

Sınıf ağırlıkları dengesiz sınıf dağılımlarına sahip veri kümeleri için kullanılan önemli bir stratejidir. Çalışmada ‘compute_class_weight’ fonksiyonu, eğitim veri setindeki sınıfların dengesizliğini hesaplamak için kullanılmıştır. Bu strateji, nadir sınıfların daha fazla öneme sahip olduğu durumlarda modelin performansını artırmayı hedefler. Çalışmada, nadir sınıfların daha büyük bir etkiye sahip olmasını sağlamak için ağırlıkları, modelin eğitimi sırasında kullanılmıştır. Bu nadir sınıfların daha iyi öğrenilmesini ve modelin dengeli bir şekilde eğitilmesini sağlar. Bu stratejinin kullanımıyla, modelin test verisi üzerinde daha güvenilir sonuçlar elde etmesi ve daha iyi performans sunması sağlanmıştır.

4.3.4 Kayıp Fonksiyonu (Loss Function)

Derin öğrenme modellerinin performansını değerlendirmek ve tahminlerin doğruluğunu ölçmek için kullanılan kayıp fonksiyonları, modelin geliştirilme sürecinde kritik rol oynar. Kayıp fonksiyonu, modelin gerçek ve tahmin edilen değerleri arasındaki farkı ölçer ve bu farkı en aza indirmek için model parametrelerini günceller. Modelin performansını şekillendiren önemli bir karar olan kayıp fonksiyonun doğru seçimi, modelin başarısını ve genel performansını belirleyen kritik bir karardır. Ortalama karesel hata (mean squared error), ikili çapraz entropi (binary cross entropy) ve kategorik çapraz entropi (categorical cross entropy) gibi kayıp fonksiyonları, derin öğrenme modellerinde yaygın bir şekilde tercih edilmektedir (Goodfellow, Bengio and Courville, 2016)(Murphy, 2012)

Bu çalışmada, model eğitimi ve değerlendirilmesi için “kategorik çapraz entropi” kayıp fonksiyonu kullanılmıştır. Bu kayıp fonksiyonun tercih edilmesinin sebebi, kanserli hücre dokularının sınıflandırılmasında 5 alt sınıfın bulunmasıdır.

Bu kayıp fonksiyonu çoklu sınıflandırma problemleri için yaygın olarak tercih edilen

bir seçenektir. Bu fonksiyon, her sınıf için model tarafından tahmin edilen olasılıkların logaritmasını alır ve bunları gerçek sınıf etiketleri ile çarparak bir ortalama hesaplar. Matematiksel olarak, $Loss = - \sum_{i=1}^N y_i \log(\hat{y}_i)$ formülü ile ifade edilir. Burada y_i gerçek etiket, $\hat{y}_i$ ise modelin tahminidir (Chollet, 2021)(Bishop, Christopher M., 2006).

4.4 Kullanılan Öğrenme Aktarımı Yöntemleri ve Özelleştirmeleri

Bu çalışmada çeşitli derin öğrenme mimarileri kullanılarak yumurtalık kanseri dokularının sınıflandırılması amaçlanmıştır. İlk olarak ResNet-50, EfficientNetB0, InceptionV3, MobileNetV2, DenseNet121 mimarileri incelenmiştir ve her bir model için özel bir yaklaşım benimsenmiştir. Her model için, başlangıçta önceden eğitilmiş ağırlıkları kullanarak bir temel model oluşturulmuş ve daha sonra transfer öğrenme yöntemiyle ayarlamalar yapılmıştır. Bu aşamada, temel modelin özelliklerini koruyarak, veri kümesinin spesifik özelliklerine uyum sağlanmıştır. Bu yaklaşım ile her modelin sınıflandırma performansını arttırılarak, yumurtalık kanseri dokularının daha doğru şekilde ayırt edilmesi sağlanmıştır. Bu sayede derin öğrenme tabanlı sınıflandırma sistemi, yumurtalık kanseri teşhisi için güvenilir ve etkili bir araç olarak geliştirilmiştir.

Tablo 4.1’de temel özellikleri verilen modeller, bu bölümün devamında detaylı bir şekilde anlatılmıştır. Sırasıyla Resnet-50, EfficientB0, InceptionV3, MobileNetV2 ve DenseNet121 mimarileri incelenmiş ve her bir modelin özel katmanları, ince ayar yöntemleri detaylandırılmıştır.

Tablo 4. 1. Derin öğrenme yöntemlerinin bazı özellikleri

Mimari	Tanıtım Yılı	Katman Sayısı	Parametreler (Yaklaşık)	En İyi ImageNet Doğruluğu	Temel Özellikler/İnovasyonlar
ResNet50	2015	50	25,6 milyon	76.0 %	Artık bağlantılar, kimlik kısa yollarıyla derin ağları tanımlar
EfficientB0	2019	82	5,3 milyon	77.1 %	Genişlik, derinlik ve çözünürlüğün bileşik ölçeklenmesi, son derece verimli bir mimariyi ifade eder.
InceptionV3	2015	100+	23,8 milyon	77.2%	Yerleşik evrişim katmanları, paralel evrişimler ve azaltılmış boyutluk, derin öğrenme modellerinde yaygın olarak kullanılan tekniklerdir.
MobileNetV2	2018	53	3,4 milyon	71.8%	Hafif mimariye sahip, doğrusal aktivasyonlar, inverted residual ve derinliksel ayrılabilen evrişimleri içeren teknikler bulunmaktadır.
DenseNet121	2016	121	8 milyon	74.9%	Yoğun bağlantılar, verimli parametre kullanımı ve kaybolan gradyan problemini hafifletme, bu yöntemin temel özelliklerindendir.

4.4.1 ResNet-50

Çalışmada kullanılan ResNet-50 modeli, yumurtalık kanseri dokularının sınıflandırılmasında kritik bir rol oynamıştır. ResNet-50, 50 katmanlı derin bir evrişimli sinir ağı olup, ImageNet veri kümesi üzerinde önceden eğitilmiş ağırlıklara sahiptir.

Yapılan çalışmada, ResNet-50 modelinin eğitilmiş ağırlıkları yüklenmiş ve modelin son katmanı sınıflandırma katmanlarıyla değiştirilmiştir. Sınıflandırma yapabilmek için Global Average Pooling ve tam bağlı (Dense) katmanları eklenmiştir. Bu model önceden eğitilmiş ağırlıkları kullanarak görüntülerdeki özellikleri çıkartır ve ardından bu özellikleri sınıfları tahmin etmek için kullanır.

Çalışmanın diğer kısmında, ResNet50 modelini ince ayar yapmak amacıyla

kullanılmaktadır. Önceden eğitilmiş ResNet50 modeli yükleniyor, ancak bu sefer son katmanları dahil edilmedi ve modelin son katmanlarına özel bir sınıflandırıcı eklendi ve bu katmanlar rastgele başlatıldı. Ardından modelin son 4 katmanı donduruldu ve geri kalan katmanlar eğitilebilir hale getirilmiştir.

Her iki yaklaşımda da ResNet50 modeli temel alınmıştır, ilk kısımda önceden eğitilmiş ağırlıkları sınıflandırma için kullanırken, ikinci kısımda modeli belli bir görev için özelleştirmek ve ince ayar yapmak için kullanılmıştır.

4.4.2 EfficientB0

EfficientB0, derin öğrenme alanında önemli bir ilerleme olan ve özellik hesaplama kaynaklarına sahip olan ve özellikle sınırlı hesaplama kaynaklarına sahip cihazlarda kullanımı, kolaylaştıran verimli bir evrişimli sinir ağı mimarisidir. Bu mimarinin temel özelliği genişlik, derinlik ve çözünürlüğün etkili bir şekilde ölçeklenmesidir (Saxena, Shrivastava, 2023).

Önceden eğitilmiş EfficientB0 modeli, Imagenet veri kümesinde farklı veri kümeleri ile eğitilmiş ve genel görüntü özelliklerini yakalamak için optimize edilmiştir. Çalışmada, EfficientNetB0 modelinin önceden eğitilmiş ağırlıkları, yumurtalık kanseri sınıflandırma görevine uyarlanmıştır. Bu modelde, GlobalAveragePooling2D katmanı, evrişimli katmanlardan gelen özellik haritalarını özetlemek amacıyla kullanılmıştır. Bu katman, her kanalın ortalamasını alarak sabit boyutlu bir özellik vektörü oluşturur. Ardından tam bağlantılı yoğun katmanlarla (Dense) ve bir softmax aktivasyon fonksiyonu ile sonuç katmanı oluşturulmuştur. Bu katman ile yumurtalık kanseri girdi görüntülerinin sınıflandırma tahminlerine dönüştürülmesi sağlanmıştır.

Önceden eğitilmiş ağırlıklarla yüklenmiş temel model, yumurtalık kanseri hücrelerinin sınıflandırılması görevi için daha uygun hale getirilmiş ve ince ayar adımı uygulanmıştır. Bu adım, modelin sınıflandırma görevine daha iyi uyum sağlaması için yapılmıştır.

4.4.3 InceptionV3

Çalışmada, yumurtalık kanseri hücre dokularını sınıflandırmak için kullanılan mimarilerden biri, Google tarafından geliştirilen ve ImageNet veri kümesinde eğitilmiş olan InceptionV3 modelidir. İlk olarak InceptionV3 modeli önceden eğitilmiş ağırlıklarla son sınıflandırma katmanı dahil edilmeden yüklenmiştir. Son sınıflandırma katmanının dahil edilmemesi ile modelin temel özellik çıkarıcı katmanları korunmuştur. Tüm katmanların dondurulması ile önceden eğitilmiş ağırlıkların değiştirilmesi engellenmiştir. Sonrasında,

modelin çıktısı özellik haritalarının boyutunu küçülterek her bir kanalın ortalamasını alan ve sabit boyutlu bir vektör oluşturan ‘GlobalAveragePooling2D’ katmanına verilmiştir. Ardından, her biri 128 nöronlu ve ReLU aktivasyon fonksiyonu kullanan iki adet ‘Dense’ katmanı eklenmiştir. Eklenen bu tam bağlantılı katmanlar ile çıkarılan özellikler daha karmaşık ilişkilerin öğrenilmesi için kullanılmıştır. Aktivasyon fonksiyonu olarak softmax kullanılarak 5 sınıflı bir Dense çıktı katmanı eklenmiş ve modelin kanserli hücre dokularını sınıflandırması sağlanmıştır.

311 katmandan oluşan bu modelde, kanserli hücre dokularına daha iyi adapte olması için yapılan ince ayar işleminde, son dört katman hariç 307 katman dondurulmuş ve son dört katman tekrar eğitilebilir hale getirilmiştir.

4.4.4 MobileNetV2

MobileNetV2, düşük bellek ve işlemci kaynaklarına sahip olan cihazlarda etkili bir şekilde çalışabilen, hafif ve optimize edilmiş bir evrişimli sinir ağı modelidir (Dong, Zhou, Ruan, 2020). Kaynakları verimli kullanan ve geniş bir kullanıcı kitlesi için erişilebilir olan MobileNetV2, çalışmamızda tercih edilen mimarilerden biri olmuştur. Önceden eğitilmiş MobileNetv2 modeli, yumurtalık kanseri görüntülerini sınıflandırma görevi için kullanılarak model eğitime başlanmıştır. Özel katmanlar eklenerek devam edilir. GlobalAveragePooling2D katmanı, özellik haritasının boyutunu küçülterek her kanalın ortalamasını alır ve ağı özelliğini daha küçük boyutlu bir vektörde özetler. Sonrasında gelen yoğun (Dense) katmanlar, bu özetlenmiş özellikler üzerinde sınıflandırma yapmak için kullanılır. İlk yoğun katmanda, 128 nöron ve ReLU aktivasyon fonksiyonu bulunur. Daha sonra gelen Dropout katmanı, aşırı uyumu engellemek için kullanılır. Bu katman, eğitim sırasında belirli bir oranda nöronları rastgele olarak devre dışı bırakarak ağı genelleme yeteneğini artırır. Son olarak, softmax aktivasyon fonksiyonu ile son sınıflandırma katmanı eklenir. Bu katman, ağı çıktısını sınıflar arasında olasılık dağılımı olarak döndürür, böylece giriş görüntüsünün her bir sınıfa ait olma olasılığını tahmin eder. Bu katmanlar, MobileNetV2 modelinden gelen özellikler üzerinde özel bir sınıflandırma katmanı oluşturarak, belirli bir görev için daha spesifik bir model oluşturmak üzere birleştirilir.

Oluşturulan modelin yumurtalık kanseri dokularını daha doğru bir şekilde sınıflandırabilmesi için ince ayar işlemi gerçekleştirilmiştir. Önceden eğitilmiş MobileNetV2 modelinin, son 4 katmanı tekrar eğitilebilir hale getirilir. Gerçekleştirilen ince ayar işlemi, modelin önceden eğitilmiş ağına daha özel bir veri setine daha uyum sağlamasını sağlar.

4.4.5 DenseNet121

Bu çalışmada, yumurtalık kanseri dokularının sınıflandırılması amacıyla transfer öğrenme yöntemi kullanılarak TensorFlow Keras kütüphanesinden DenseNet121 mimarisi üzerinde bir model oluşturulmuştur. DenseNet121, evrişimsel sinir ağları arasında öne çıkan bir modeldir. Bu model, katmanlar arasındaki yoğun bağlantılar ile bilinir. Bu yoğun bağlantılar, gradyan akışını geliştirir ve özelliklerin daha verimli bir şekilde yeniden kullanılmasını sağlar. Bu özellikler, özellikle görüntü tanıma görevlerinde son derece etkili olabilir.

İlk olarak, DenseNet121 modeli, ImageNet veri seti üzerinde önceden eğitilmiş ağırlıklarla birlikte yüklenir, ancak üst katmanlar hariç sadece evrişimsel tabanı korunur. Bu taban model, yeni veri setine özgü yüksek seviyeli özellikleri uyarlayabilmek için son dört katman hariç dondurulur. Bu şekilde, sadece bu katmanlar ince ayar için açık bırakılır ve diğer katmanlar sabitlenir.

Özel katmanlar, modelin üstüne eklenir. İlk olarak, özellik haritalarının uzamsal boyutlarını azaltmak için GlobalAveragePooling2D katmanı eklenir. Ardından, ReLU aktivasyonlu iki tam bağlı (Dense) katman ve aşırı öğrenmeyi önlemek için dropout düzenlemesi uygulanır. Son katman, giriş görüntülerini beş farklı sınıfa ayırmak için softmax aktivasyonlu bir Dense katmandır. Model, Adam optimizasyon algoritmasını kullanmaktadır ve öğrenme oranı 0.001 olarak belirlenmiştir. Eğitim verilerine veri çoğaltma uygulanarak genel performans artırılır. Eğitim süreci sırasında, erken durdurma, model kontrol noktası kaydetme ve öğrenme oranı azaltma gibi çeşitli geri çağırım fonksiyonlar kullanılmıştır.

4.5 Değerlendirme Metrikleri

Derin öğrenme yöntemlerinin yumurtalık kanseri hücrelerini sınıflandırmadaki performanslarını değerlendirmek amacıyla doğruluk, hassasiyet, duyarlılık ve F1-puanı metrikleri kullanılmıştır. Kullanılan metriklerle, derin öğrenme yöntemlerinin yumurtalık kanseri teşhisindeki etkinliği karşılaştırılmış ve en etkili yöntemin belirlenmesi sağlanmıştır.

Bu metriklerin hesaplanabilmesi için, karmaşıklık matrisinden elde edilen doğru pozitif (DP), yanlış pozitif (YP), yanlış negatif (YN) ve doğru negatif (DN) değerleri kullanılmıştır. Kullanılan değerlerin açıklamaları ve Tablo 4.2' de verilmiştir.

Tablo 4. 2. Değerlendirme Metrikleri

GERÇEK DEĞERLER			
TAHİN EDİLEN DEĞERLER		POZİTİF	NEGATİF
	POZİTİF	Doğru Pozitif (DP) Tahmin edilen pozitif veriler doğru şekilde tahmin edilmiştir.	Yanlış Pozitif (YP) Negatif olarak bilinen veriler pozitif kabul edilmiştir.
	NEGATİF	Yanlış Negatif (YN) Pozitif olarak bilinen negatif tahmin edilmiştir	Doğru Negatif (DN) Negatif olarak bilinen veriler negatif olarak tahmin edilmiştir.

Çalışmada doğruluk hassasiyet, geri çağırma ve F1 puanı metrikleri kullanarak modellerin performansı değerlendirilmiştir. Bu metriklerin hesaplanması Eşitlik 4.1, 4.2, 4.3 ve 4.4 kullanılmaktadır.

$$\text{Doğruluk(Accuracy)} = \frac{DP+DN}{(DP+DN+YP+YN)} \quad (4.1)$$

$$\text{Hassasiyet(Precision)} = \frac{DP}{(DP+YP)} \quad (4.2)$$

$$\text{Geri Çağırma(Recall)} = \frac{DP}{(DP+YN)} \quad (4.3)$$

$$\text{F1 Skor} = \frac{2 * (\text{Hassasiyet} * \text{Geri Çağırma})}{(\text{Hassasiyet} + \text{Geri Çağırma})} \quad (4.4)$$

5. BULGULAR VE DEĞERLENDİRME

Bu çalışmada, çeşitli derin öğrenme mimarilerinin performansını karşılaştırmak amacıyla ResNet-50, EfficientB0, InceptionV3, MobileNetV2 ve DenseNet121 modelleri kullanılmıştır. Her bir model, belirli bir veri kümesi üzerinde eğitilmiş ve test edilmiştir. Elde edilen sonuçlar, her bir mimarinin doğruluk, kayıp ve hesaplama verimliliği ölçütlerine göre değerlendirilmiştir. Alt bölümlerde, her bir modelin performansına dair ayrıntılı sonuçlar sunulmuş ve analiz edilmiştir. Bu modelleri daha iyi tanımlayabilmek için her biri üç farklı yapılandırma ile değerlendirilmiştir. Bu yapılandırmalar için temel, ağırlıklı ve ince ayarlı olmak üzere Türkçe isimlendirmeler yapılmıştır;

Temel: Bu yapılandırmada, ilgili temel model mimarisi kullanılarak katmanlar dondurulmuş ve üzerine sadece dense katmanları eklenmiştir. Örneğin, ResNet-50 için bu model "ResNet50_Temel" olarak adlandırılmıştır. Benzer şekilde, EfficientNetB0 için "EfficientB0_Temel", InceptionV3 için "InceptionV3_Temel", MobileNetV2 için "MobileNetV2_Temel" ve DenseNet121 için "DenseNet121_Temel" adları kullanılmıştır. Bu yapılandırmada, orijinal veri seti kullanılmıştır.

Ağırlıklı: Bu yapılandırmada, model sınıf ağırlıkları ile ağırlıklandırılmış kategorik çapraz entropi kaybı ile eğitilmiştir. Örneğin, ResNet-50 için bu model "ResNet50_Ağırlıklı" olarak adlandırılmıştır. Diğer modeller için ise sırasıyla "EfficientB0_Ağırlıklı", "InceptionV3_Ağırlıklı", "MobileNetV2_Ağırlıklı" ve "DenseNet121_Ağırlıklı" isimleri kullanılmıştır. Bu yapılandırmada, veri seti artırma teknikleri (data augmentation) uygulanarak eğitim verilmiştir.


İnce Ayarlı: Bu yapılandırmada, ilgili modelin son birkaç katmanı yeniden eğitilmek üzere serbest bırakılmış ve dropout katmanları eklenmiştir. Örneğin, ResNet-50 için bu model "ResNet50_İnceAyarlı" olarak adlandırılmıştır. Diğer modeller için ise sırasıyla "EfficientB0_İnceAyarlı", "InceptionV3_İnceAyarlı", "MobileNetV2_İnceAyarlı" ve "DenseNet121_İnceAyarlı" isimleri kullanılmıştır. Bu yapılandırmada da veri seti artırma teknikleri kullanılarak eğitim yapılmıştır.

Bu isimlendirmeler, her bir modelin yapılarını ve eğitim süreçlerini Türkçe olarak daha iyi ifade edeceği düşünüldüğünden çalışmada bu terminoloji kullanılmıştır.

5.1 Resnet50 Mimarisi Sonuçlar

Bu bölümde, ResNet50 mimarisinin eğitim, doğrulama ve test verileri üzerinde elde edilen sonuçları incelenmiştir. Modelin performansı, doğruluk, kayıp, sınıflandırma raporu ve karmaşıklık matrisi değerlendirilmiştir. ResNet50 modeli, önceden eğitilmiş ImageNet ağırlıkları ile başlatılmış ve belirli katmanları dondurularak ince ayar yapılmıştır. Modelin eğitimi sırasında veri artırma teknikleri kullanılmıştır. Eğitim verilerinde 25 epoch boyunca eğitim yapılmış ve her epoch sonunda doğrulama verileri üzerinde değerlendirme yapılmıştır. Eğitim sırasında erken durdurma (early stopping) ve en iyi model kontrolü (model checkpoint) gibi geri çağırma (callback) mekanizmaları kullanılmıştır.

Şekil 5.1’de, ResNet50 modelinin üç farklı yapılandırmasının (Temel, Ağırlıklı, İnce Ayarlı) eğitim ve doğrulama kaybı ve doğruluğu grafiklerle gösterilmiştir. İlk grafikte (a) ResNet50_Temel modeli için eğitim kaybının hızlı bir şekilde azaldığı, ancak doğrulama kaybının dalgalandığı ve belirli bir seviyede sabit kaldığı görülmektedir. Eğitim doğruluğu hızla artarken, doğrulama doğruluğu dalgalanarak daha düşük seviyelerde seyretmektedir. İkinci grafikte (b) ResNet50_Ağırlıklı modeli, eğitim kaybında hızlı bir azalma gösterirken, doğrulama kaybı dalgalanmaktadır ve istikrarlı bir iyileşme göstermemektedir. Eğitim doğruluğu yüksek seviyelerdeyken, doğrulama doğruluğu belirgin dalgalanmalarla orta seviyelerde kalmaktadır. Üçüncü grafikte (c) ResNet50_İnceAyarlı modeli ise hem eğitim hem de doğrulama kayıplarında belirgin bir azalma ve daha kararlı bir doğrulama doğruluğu ile en iyi performansı sergilemektedir. Eğitim doğruluğu ve doğrulama doğruluğu hızla artmakta ve yüksek seviyelerde sabitlenmektedir. Bu sonuçlar, ince ayarlı modelin diğer yapılandırmalara kıyasla daha iyi genel performans sergilediğini göstermektedir.



Şekil 5. 1. ResNet50 Kayıp ve Doğruluk Grafikleri

Tablo 5.1’de sunulan ResNet50_Temel modelinin performansı beş farklı sınıf için doğruluk, hassasiyet, geri çağırma ve F1-puanı değerleri üzerinden değerlendirildiğinde, modelin genel olarak %84 doğrulukla istikrarlı bir performans sergilediği görülmektedir. Endometri sınıfında model, %100 hassasiyet, geri çağırma ve F1-puanı ile en yüksek performansı göstermektedir. Mucinous sınıfında da yüksek başarı (%84 doğruluk, %82 hassasiyet, %90 geri çağırma, %86 F1-puanı) elde edilmiştir. Clear_Cell (%70 geri çağırma) ve Non_Cancerous (%73 hassasiyet) sınıflarında ise performans görece düşüktür. Serous sınıfında model, %84 doğruluk, %89 hassasiyet, %80 geri çağırma ve %84 F1-puanı ile genel olarak başarılıdır.

Tablo 5. 1. ResNet50_Temel Sınıf Bazlı Sonuçlar

Sınıflar	Doğruluk	Hassasiyet	Geri Çağırma	F1-Puanı
Clear_Cell	0,84	0,78	0,70	0,74
Endometri	0,84	1,00	1,00	1,00
Mucinous	0,84	0,82	0,90	0,86
Non_Cancerous	0,84	0,73	0,80	0,76
Serous	0,84	0,89	0,80	0,84

Tablo 5.1’de görüleceği üzere, modelin genel performansı umut verici olmakla birlikte,

bazı sınıflarda (özellikle Mucinous ve Serous) doğru pozitifleri kaçırma eğilimi gözlemlenmiştir. Bu durum, modelin bu sınıfları daha iyi tanıyabilmesi için daha fazla eğitim veya veri artırma tekniklerine ihtiyaç duyabileceğini göstermektedir.

Tablo 5.2’de verilen ResNet50_Ağırlıklı modeli, beş farklı sınıf için %93 doğrulukla yüksek performans sergilemektedir. Clear_Cell sınıfında %92 hassasiyet ve %84 geri çağırma ile güçlü bir performans göstermektedir. Endometri sınıfında %96 hassasiyet ve %99 geri çağırma ile çok yüksek başarı sağlanmıştır. Mucinous sınıfında %83 hassasiyet ve %97 geri çağırma, Non_Cancerous sınıfında %98 hassasiyet ve %93 geri çağırma, Serous sınıfında ise %98 hassasiyet ve %91 geri çağırma değerleri elde edilmiştir. Genel olarak, model tüm sınıflarda dengeli ve yüksek performans sergilemektedir.

Tablo 5. 2. ResNet50_Ağırlıklı Sınıf Bazlı Sonuçlar

Sınıflar	Doğruluk	Hassasiyet	Geri Çağırma	F1-Puanı
Clear_Cell	0,93	0,92	0,84	0,88
Endometri	0,93	0,96	0,99	0,97
Mucinous	0,93	0,83	0,97	0,90
Non_Cancerous	0,93	0,98	0,93	0,96
Serous	0,93	0,98	0,91	0,95


ResNet50_İnceAyarlı modelinin performans metrikleri, Tablo 5.3'te görüldüğü gibi genel olarak oldukça yüksektir ve modelin sınıflandırma görevinde başarılı olduğunu göstermektedir. Her bir sınıf için doğruluk, hassasiyet, geri çağırma ve F1-puanı değerleri aşağıda detaylı olarak incelenmiştir.

Ancak özellikle Mucinous ve Serous sınıflarında hassasiyetin artırılması, modelin performansını daha da iyileştirebilir. Bu sonuçlar, modelin sınıflandırma görevinde genellikle başarılı olduğunu, ancak belirli sınıflarda daha dikkatli optimizasyon gerektirdiğini ortaya koymaktadır.


Tablo 5. 3. ResNet50_İnceAyarlı Sınıf Bazlı Sonuçlar

Sınıflar	Doğruluk	Hassasiyet	Geri Çağırma	F1-Puanı
Clear_Cell	0,95	0,98	0,91	0,95
Endometri	0,95	0,99	0,96	0,97
Mucinous	0,95	0,90	0,97	0,93
Non_Cancerous	0,95	0,97	0,96	0,96
Serous	0,95	0,92	0,96	0,94

Sınıf bazlı sonuçların ardından, modellerin performansını daha detaylı analiz edebilmek için karmaşıklık matrisleri incelenmiştir. Her bir model için elde edilen karmaşıklık matrisleri, gerçek ve tahmin edilen sınıflar arasındaki ilişkileri göstermektedir. ResNet50_Temel, ResNet50_Ağırlıklı ve ResNet50_İnceAyarlı modellerine ait karmaşıklık matrisleri sırasıyla Şekil 5.2, Şekil 5.3 ve Şekil 5.4'te gösterilmiştir.


**Şekil 5. 2.** ResNet50_Temel Karmaşıklık Matrisi

Şekil 5.2'de gösterilen karmaşıklık matrisi (Confusion Matrix) test verileri üzerindeki model performansını sınıf bazında ayrıntılı olarak sunmaktadır. Matriste her satır gerçek sınıfları, her sütun ise tahmin edilen sınıfları temsil etmektedir.



Şekil 5. 3. ResNet50_Ağırlıklı Karmaşıklık Matrisi

Şekil 5.3 incelendiğinde genel olarak, modelin performansı oldukça yüksektir; ancak özellikle Mucinous ve Clear_Cell sınıflarında hataların biraz daha fazla olduğu görülmektedir. Bu, modelin bu sınıflarda daha fazla iyileştirmeye ihtiyaç duyabileceğini gösterebilir.




Şekil 5. 4. ResNet50_İnceAyarlı Karmaşıklık Matrisi

Şekil 5.4'teki karmaşıklık matrisi, ince ayar yapılan modelin sonuçlarının oldukça olumlu olduğunu göstermektedir.

5.2 EfficientNetB0 Mimarisi Sonuçlar

Bu bölümde, EfficientNetB0 mimarisinin test verileri üzerinde elde edilen sonuçlar sunulmaktadır. Bu sonuçlar, her sınıf için doğruluk, hassasiyet, geri çağırma ve F1 puanı metrikleri ile değerlendirilmiştir. Bu değerler, modelin her bir sınıfı ne kadar doğru bir şekilde sınıflandırdığını, yanlış pozitif ve yanlış negatif sonuçları nasıl ele aldığını ve genel performansını göstermektedir. Bu bölüm, EfficientNetB0 modelinin sınıflandırma yeteneğini kapsamlı bir şekilde değerlendirmek için kullanılmıştır.

EfficientB0 mimarisi için "EfficientB0_Temel", "EfficientB0_Ağırlıklı" ve "EfficientB0_InceAyarlama" olmak üzere üç farklı çalışma gerçekleştirilmiştir. Bu çalışmaların başarımlarını grafikleri Şekil 5.5'te sunulmuştur. Kayıp ve doğruluk grafiklerine bakıldığında, ağırlıklı ve ince ayarlı yöntemlerin temel yöntemle göre daha hızlı ve istikrarlı bir şekilde modelin performansını artırdığı görülebilir. İnce ayarlı yöntemin genellikle daha hızlı bir şekilde eğitildiği ve daha yüksek bir doğruluk elde ettiği gözlemlenmiştir. Bu sonuçlar, modelin daha iyi genelleştirme yeteneğine sahip olduğunu ve daha dengeli bir performans sergilediğini göstermektedir.



Şekil 5. 5. EfficientNetB0 Kayıp ve Doğruluk Grafikleri

Tablo 5.4'te, EfficientNetB0 modeli için sınıf bazlı sonuçlar, her bir sınıf için doğruluk yüksek olsa da sınıflar arasında hassasiyet, geri çağırma ve F1 puanlarında önemli farklılıklar

vardır. Örneğin, "Serous" sınıfında hassasiyet yüksekken geri çağırma düşüktür, bu, modelin bu sınıfı doğru bir şekilde belirlemede zorlandığını gösterebilir. "Endometri" sınıfı yüksek hassasiyet ve geri çağırma değerleriyle dikkat çekerken, "Non_Cancerous" sınıfında geri çağırma değeri mükemmel olsa da hassasiyet düşüktür. Bu durum, modelin kanser dışı hücreleri tanımlamada başarılı olduğunu ancak yanlış pozitif sonuçlar verebileceğini gösterebilir. Sonuç olarak, modelin bazı sınıflarda iyi performans gösterdiği ancak diğerlerinde iyileştirilmesi gerektiği görülmektedir.

Tablo 5. 4. EfficientNetB0_Temel için Sınıf Bazlı Sonuçlar

Sınıflar	Doğruluk	Hassasiyet	Geri Çağırma	F1-Puanı
Clear_Cell	0,86	0,82	0,90	0,86
Endometri	0,86	0,91	1,00	0,95
Mucinous	0,86	0,90	0,90	0,90
Non_Cancerous	0,86	0,77	1,00	0,87
Serous	0,86	1,00	0,50	0,67

EfficientNetB0_Ağırlıklı için Sınıf Bazlı Sonuçlar Tablo 5.5'te sunulmuştur. Bu tablo, modelin her sınıf için elde ettiği doğruluk, hassasiyet, geri çağırma ve F1 puanı gibi performans ölçütlerini içermektedir.

Tablo 5. 5. EfficientNetB0_Ağırlıklı Sınıf Bazlı Sonuçlar

Sınıflar	Doğruluk	Hassasiyet	Geri Çağırma	F1-Puanı
Clear_Cell	0,94	0,98	0,86	0,92
Endometri	0,94	0,96	0,99	0,98
Mucinous	0,94	0,89	0,95	0,92
Non_Cancerous	0,94	0,91	0,98	0,95
Serous	0,94	0,97	0,92	0,95

Modelin genel performansının yüksek olduğu (%94 doğruluk) gözlemlenmektedir. Sınıf bazlı analizde, çoğu sınıf için yüksek hassasiyet ve geri çağırma değerleri görülmektedir. Ancak "Clear_Cell" sınıfında Geri Çağırma değerinin biraz düşük olduğu (%86), modelin bu sınıfı doğru

bir şekilde tanımlamada kısmen zorlanabileceğini işaret etmektedir. Yine de bu sonuçlar, EfficientNetB0_Ağırlıklı modelinin genel olarak veri setinde etkili bir performans sergilediğini göstermektedir.


EfficientNetB0_İnceAyarlı için Sınıf Bazlı Sonuçlar tablo 5.6'da sunulmuştur. Bu tablo, her sınıf için doğruluk, hassasiyet, geri çağırma ve F1 puanı gibi performans metriklerini içerir. Modelin yüksek doğruluk elde ettiği (%97 doğruluk) gözlemlenmektedir. Sınıf bazlı analizde, her sınıf için yüksek hassasiyet, geri çağırma ve F1 puanlarına ulaşılmıştır. Bu bulgular, EfficientNetB0_İnceAyarlı modelinin veri setinde yüksek doğruluk sergilediğini göstermektedir.

Tablo 5. 6. EfficientB0_İnceAyarlı Sınıf Bazlı Sonuçlar

Sınıflar	Doğruluk	Hassasiyet	Geri Çağırma	F1-Puanı
Clear_Cell	0,97	0,97	0,96	0,96
Endometri	0,97	1,00	0,99	0,99
Mucinous	0,97	0,96	0,95	0,96
Non_Cancerous	0,97	0,96	0,98	0,97
Serous	0,97	0,95	0,96	0,96

Genel olarak, tüm EfficientNetB0 modelleri (Temel, Ağırlıklı ve İnce Ayarlı) yüksek doğruluk oranları elde etmiştir. Sınıf bazlı sonuçlar incelendiğinde, her üç modelin de çoğu sınıf için yüksek hassasiyet, geri çağırma ve F1 puanlarına sahip olduğu görülmektedir. Bu sonuçlar, EfficientNetB0 mimarisinin veri setinde etkili bir şekilde performans gösterdiğini ve çeşitli sınıfları doğru bir şekilde tanımlayabildiğini göstermektedir.


"EfficientB0_Temel", "EfficientB0_Ağırlıklı" ve "EfficientB0_İnceAyarlı" çalışmalarına ait karmaşıklık matrisleri incelenmiştir. Bu matrisler, her bir çalışmanın sınıflandırma performansını ayrıntılı bir şekilde değerlendirmektedir.



Şekil 5. 6. EfficientNetB0_Temel Karmaşıklık Matrisi

Şekil 5.6 incelendiğinde özellikle "Clear_Cell" sınıfında bazı yanlış tahminlerin olduğu dikkat çekmektedir. Ancak, genel olarak modelin iyi bir performans sergilediği gözlemlenmektedir.

Şekil 5.7'deki EfficientB0_Ağırlıklı karmaşıklık matrisine bakıldığında, bazı sınıflarda karışıklık olduğu gözlemlenirken, özellikle "Clear_Cell" ve "Non_Cancerous" sınıflarında yanlış tahminlerin olduğu belirlenmiştir. Bununla birlikte, genel olarak modelin dengeli ve kabul edilebilir bir performans sergilediği gözlenmektedir.




Şekil 5. 7. EfficientB0_Ağırlıklı Karmaşıklık Matrisi

İnce ayar işleminden elde edilen karmaşıklık matrisi, Şekil 5.8’de sunulmuştur. Sonuçlar incelendiğinde, modelin ince ayar sonrasında daha iyi bir performans gösterdiği belirlenmiştir. Özellikle, "Clear_Cell" ve "Non_Cancerous" sınıflarında daha az yanlış tahmin yapılmış gibi görünmektedir. Bu, modelin daha spesifik sınıfları daha doğru bir şekilde tanıyabildiğini göstermektedir. Genel olarak, ince ayarın modelin performansını artırdığı ve daha hassas tahminler yapmasına yardımcı olduğu görülmektedir.

5.3 InceptionV3 Mimarisi Sonuçları

Bu bölümde InceptionV3 mimarisi performansı ayrıntılı bir şekilde değerlendirilmiş ve sonuçlar analiz edilmiştir. Bu bölümde, InceptionV3 mimarisinin "Temel", "Ağırlıklı" ve "İnce Ayarlı" sürümlerinin sonuçlarını detaylı olarak incelenmiştir. Elde edilen sonuçlar, modelin doğruluğu, kaybı, sınıflandırma raporu ve karmaşıklık matrisi temel alınarak ayrıntılı bir analize tabi tutularak karşılaştırılmıştır. Yapılan eğitimlerin sonuçlarına ilişkin başarı grafikleri, aşağıdaki Şekil 5.8’de sunulmuştur.



Şekil 5. 8. InceptionV3 Kayıp ve Doğruluk Grafikleri

InceptionV3 mimarisinin sınıf bazlı performansı değerlendirilmiş ve her sınıf için modelin etkinliği ayrı ayrı incelenmiştir. Her bir sınıf için doğruluk, hassasiyet, geri çağırma ve F1 puanları gibi ölçütler değerlendirilmiştir. Bu değerlendirmeler, modelin farklı sınıfları ne kadar doğru bir şekilde tanımlayabildiğini göstermektedir.

Tablo 5.7’de, InceptionV3_Temel modelinin sınıf bazlı performans sonuçları ayrıntılı olarak yer almaktadır. Her sınıf için önemli performans göstergeleri olan doğruluk, hassasiyet, geri çağırma ve F1 puanı gibi kritik metrikler detaylı bir şekilde analiz edilmiş ve modelin sınıfları tanıma kabiliyeti detaylı olarak değerlendirilmiştir.

Tablo 5. 7. InceptionV3_Temel Sınıf Bazlı Sonuçlar

Sınıflar	Doğruluk	Hassasiyet	Geri Çağırma	F1-Puanı
Clear_Cell	0,56	0,75	0,30	0,43
Endometri	0,56	0,89	0,80	0,84
Mucinous	0,56	0,40	0,40	0,40
Non_Cancerous	0,56	0,38	0,80	0,52
Serous	0,56	0,98	0,50	0,62

Tablo5.7’de InceptionV3_Temel modelinin sınıf bazlı sonuçlarını değerlendirdiğimizde, bazı sınıflarda modelin performansının zayıf olduğunu gözlemlenmektedir. Özellikle "Clear_Cell", "Mucinous" ve "Non_Cancerous" sınıflarında düşük geri çağırma (recall) değerlerine dikkat çekmektedir, bu da modelin bu sınıflardaki gerçek pozitifleri doğru bir şekilde tanıma oranının düşük olduğunu göstermektedir. Bununla birlikte, "Endometri" ve "Serous" sınıflarında daha yüksek hassasiyet (precision) ve geri çağırma (recall) değerleri elde edilmiştir, bu da modelin bu sınıfları daha iyi tanıma yeteneğini işaret etmektedir. Genel olarak, modelin ortalama doğruluk değeri düşük olmasına rağmen, bazı sınıflarda iyi bir performans sergilediği gözlenmektedir. Tablo5.8’de, InceptionV3_Ağırlıklı mimarisi için sınıf bazlı sonuçlar gösterilmektedir.

Tablo 5. 8. InceptionV3_Ağırlıklı Sınıf Bazlı Sonuçlar

Sınıflar	Doğruluk	Hassasiyet	Geri Çağırma	F1-Puanı
Clear_Cell	0,90	0,89	0,83	0,86
Endometri	0,90	0,94	0,97	0,95
Mucinous	0,90	0,85	0,90	0,88
Non_Cancerous	0,90	0,89	0,92	0,90
Serous	0,90	0,93	0,88	0,90

Tablo 5.8’de verilen sonuçlara göre, InceptionV3_Ağırlıklı modeli her sınıf için yüksek

doğruluk oranlarına sahiptir, genellikle %90'ın üzerindedir. "Endometri" sınıfında en yüksek hassasiyet ve F1 puanı elde edilirken, "Mucinous" sınıfında en düşük hassasiyet görülmektedir. "Clear_Cell" sınıfı ise geri çağırma değeri ile dikkat çekerken, diğer sınıflara kıyasla daha düşük hassasiyet ve F1 puanı değerlerine sahiptir. InceptionV3_Temel ile karşılaştırıldığında, InceptionV3_Ağırlıklı modelinin genellikle daha yüksek doğruluk ve hassasiyet değerlerine sahip olduğu gözlemlenmiştir.


İnce Ayarlı InceptionV3 modeli için elde edilen sınıf bazlı sonuçlar Tablo 5.9 verilmiştir, her bir sınıf için farklı performans ölçütlerinin olduğu görülmektedir. "Endometri" ve "Serous" sınıfları, diğerlerine kıyasla daha yüksek hassasiyet ve F1 puanlarına sahiptir, bu da modelin bu sınıfları daha iyi tanıma eğiliminde olduğunu gösterir. Ancak, "Mucinous" sınıfı, diğer sınıflara kıyasla daha düşük hassasiyet ve F1 puanı ile dikkat çeker.

Tablo 5. 9. InceptionV3_İnceAyarlı Sınıf Bazlı Sonuçlar

Sınıflar	Doğruluk	Hassasiyet	Geri Çağırma	F1-Puanı
Clear_Cell	0,69	0,79	0,66	0,72
Endometri	0,69	0,90	0,89	0,90
Mucinous	0,69	0,41	0,43	0,42
Non_Cancerous	0,69	0,57	0,66	0,61
Serous	0,69	0,80	0,78	0,79


İnce ayarın InceptionV3 modeli için beklenen performans artışını sağlamadığı gözlemlenmektedir. Özellikle "Mucinous" sınıfı için düşük hassasiyet ve F1 puanı, modelin bu sınıfı doğru bir şekilde tanıma yeteneğinin sınırlı olduğunu göstermektedir. Bununla birlikte, diğer sınıflarda belirgin bir iyileşme sağlanmamıştır, bu da ince ayarın genel model performansını artırmadığını işaret etmektedir.

InceptionV3 modeli için elde edilen sonuçlara dayanarak, sınıflar arasındaki karışıklığı ayrıntılı olarak incelemek adına karmaşıklık matrislerine geçilmektedir. InceptionV3_Temel için karmaşıklık matrisi Şekil 5.9'da sunulmuştur. Matris, modelin her sınıf için doğru ve yanlış sınıflandırma sayılarını göstermektedir.




Şekil 5. 9. InceptionV3_Temel Karmaşıklık Matrisi

InceptionV3_Ağırlıklı modelinin değerlendirilmesinde, karmaşıklık matrisi Şekil 5.10'da görselleştirilmiştir. Modelin sınıflar arasındaki ayırım gücünün kabul edilebilir düzeyde olduğu gözlemlenmektedir.



Şekil 5. 10. InceptionV3_Ağırlıklı Karmaşıklık Matrisi

Bu modelin son versiyonu olan InceptionV3_İnce Ayar'ın karmaşıklık matrisi Şekil 5.11'de sunulmaktadır.



Şekil 5. 11. InceptionV3_İnceAyar Karmaşıklık Matrisi

İnce ayar sonrası elde edilen InceptionV3_İnceAyar modelinin karmaşıklık matrisi (Şekil 5.11), modelin bazı sınıflar arasında ciddi karışıklıklar yaşadığını ve yüksek yanlış sınıflandırma oranları olduğunu göstermektedir. Özellikle "Mucinous" ve "Non_Cancerous" sınıflarında performans düşüklüğü dikkat çekmektedir. Bu sonuçlar, ince ayar işleminin modelin performansını beklenen düzeyde iyileştiremediğini göstermektedir.

Genel olarak, InceptionV3_Ağırlıklı modelinin en dengeli ve yüksek performansı sergilediği, ancak bazı sınıflarda hala iyileştirmeye ihtiyaç duyduğu gözlemlenmiştir. İnce ayar işlemi ise karmaşıklık ve hata oranları nedeniyle modelin performansını düşürmüştür. Bu analizler, her bir modelin güçlü ve zayıf yönlerini belirlememize yardımcı olmakta ve gelecekteki geliştirme çalışmalarında dikkate alınmalıdır.


InceptionV3 mimarisi üzerine yapılan kapsamlı analizlerin ardından, MobileNetV2 mimarisiyle elde edilen sonuçlar incelenmiştir.

5.4 MobileNetV2 Mimarisi Sonuçları

Bu bölümde, çeşitli eğitim stratejileri kullanılarak eğitilen MobileNetV2 modellerinin performansı ve sınıf bazlı sonuçları değerlendirilmiştir. Doğruluk, hassasiyet, geri çağırma ve F1 puanı gibi önemli performans ölçütlerine odaklanarak, MobileNetV2'nin performansı detaylı bir şekilde ele alınmıştır.

İlk olarak, MobileNetV2 modellerinin başarımlarına odaklanılmıştır. Bu grafikler,

modelin doğruluk ve kayıp değerlerinin eğitim ve doğrulama süreçleri boyunca nasıl değiştiğini göstermektedir. İlgili başarı grafikleri Şekil 5.12’de sunulmaktadır.



Şekil 5. 12. MobileNetV2 Doğruluk ve Kayıp Grafikleri

Grafiklerin analizleri tamamlandıktan sonra, her üç MobileNetV2 modelinin (Temel, Ağırlıklı, İnce Ayarlı) sınıf bazlı sonuçları incelenmiştir. Her modelin çeşitli sınıflar üzerindeki doğruluk, hassasiyet, geri çağırma ve F1 puanı gibi önemli performans ölçütleri detaylı tablolar halinde gösterilmektedir. Bu değerlendirmeler, modellerin sınıflandırma yeteneklerini karşılaştırmasına ve hangi modelin hangi sınıflarda daha başarılı olduğunu belirlemesine olanak sağlamaktadır. MobileNetV2_Temel mimarisi için sınıf bazlı sonuçlar Tablo 5.10’da gösterilmektedir.

Tablo 5. 10. MobileNetV2_Temel Sınıf Bazlı Sonuçlar

Sınıflar	Doğruluk	Hassasiyet	Geri Çağırma	F1-Puanı
Clear_Cell	0,60	0,60	0,60	0,60
Endometri	0,60	1,00	0,50	0,67
Mucinous	0,60	0,80	0,40	0,53
Non_Cancerous	0,60	0,48	1,00	0,65
Serous	0,60	0,56	0,53	0,53

Sınıf bazlı performans metriklerini göz önünde bulundurulduğunda, sınıflar arasında belirgin bir farklılık görülmektedir. Endometri sınıfında yüksek bir hassasiyet kaydedilmiş olsa da diğer sınıfların performansında daha düşük değerler gözlemlenmiştir. Özellikle, Clear_Cell ve Serous sınıflarında hassasiyet ve F1 puanı düşüktür.

Bununla birlikte, Non_Cancerous sınıfında yüksek bir doğruluk ve F1 puanı gözlemlenmiştir. Bu değerlendirmeler, modelin sınıflandırma performansındaki bazı zayıflıkların ve iyileştirme potansiyelinin tespit edildiğini göstermektedir.

MobileNetV2_Ağırlıklı mimarisinin sınıflar için doğruluk, hassasiyet, geri çağırma ve F1 puanı değerlerini içeren sonuçlar Tablo 5.11’de aşağıda sunulmuştur.

Tablo 5. 11. MobileNetV2_Ağırlıklı Sınıf Bazlı Sonuçlar

Sınıflar	Doğruluk	Hassasiyet	Geri Çağırma	F1-Puanı
Clear_Cell	0,69	0,62	0,75	0,68
Endometri	0,69	0,70	0,78	0,73
Mucinous	0,69	0,55	0,72	0,62
Non_Cancerous	0,69	0,83	0,47	0,60
Serous	0,69	0,90	0,72	0,80

Bu tabloya göre, her sınıf için modelin performansının farklı olduğu görülmektedir. Clear_Cell ve Mucinous sınıflarında hassasiyet ve geri çağırma düşükken, Endometri ve Serous sınıflarında daha yüksektir. Non_Cancerous sınıfı ise yüksek hassasiyetle birlikte düşük geri çağırma oranıyla öne çıkmaktadır.


MobilNetV2_inceyarlı modeli için sınıf bazlı sonuçlar Tablo 5.12’de sunulmuştur. Bu sonuçlar, her sınıf için modelin sınıflandırma performansının farklı olduğunu göstermektedir. Clear_Cell ve Mucinous sınıflarında hassasiyet ve geri çağırma düşükken, Endometri ve Serous sınıflarında daha yüksektir. Non_Cancerous sınıfı ise yüksek hassasiyetle birlikte düşük geri çağırma oranıyla dikkat çekmektedir. Tabloda sunulan sonuçlar, modelin genel performansının oldukça yüksek olduğunu göstermektedir. Model, test veri kümesinde %96’lık bir doğruluk elde etmiş ve her sınıf için yüksek hassasiyet, geri çağırma ve F1 puanlarına ulaşmıştır. Bu, MobilNetV2_inceyarlı modelinin genel olarak güçlü bir sınıflandırma yeteneğine sahip

olduğunu ve veri kümesindeki farklı sınıfları başarıyla tanımlayabildiğini göstermektedir.

Tablo 5. 12. MobileNetV2_İnceAyarlı Sınıf Bazlı Sonuçlar


Sınıflar	Doğruluk	Hassasiyet	Geri Çağırma	F1-Puanı
Clear_Cell	0,96	0,96	0,93	0,95
Endometri	0,96	0,99	0,98	0,98
Mucinous	0,96	0,91	0,97	0,94
Non_Cancerous	0,96	0,98	0,97	0,97
Serous	0,96	0,95	0,95	0,95

Sınıf bazlı performans analizinin ardından, karmaşıklık matrisleri ile sınıfların doğru ve yanlış sınıflandırılma sayıları daha ayrıntılı olarak incelenmiştir. MobileNetV2_Temel için karmaşıklık matrisi Şekil 5.13'te gösterilmiştir.




Şekil 5. 13. MobileNetV2 için Karmaşıklık Matrisi

Şekil 5.14'te verilen karmaşıklık matrisi, MobileNetV2_Ağırlıklı modelinin sınıflandırma performansını görselleştirmektedir. Her satır, gerçek sınıfı temsil ederken, her sütun tahmin edilen sınıfı temsil eder. Matrisin köşegenindeki değerler doğru sınıflandırmaları gösterirken, dışındaki değerler yanlış sınıflandırmaları belirtir. Örneğin, (1,3) hücresindeki değer 73, 1. sınıfın 3. sınıfa 73 kez yanlış sınıflandırıldığını gösterir. Bu matris, modelin her bir sınıfı ne kadar doğru veya yanlış sınıflandırdığını detaylı bir şekilde ortaya koymaktadır.



Şekil 5. 14. MobileNetV2_Ağırlıklı Karmaşıklık Matrisi

Şekil 5.15'te, MobileNetV2_InceAyarlı modelinin genel olarak yüksek performans sergilediğini göstermektedir. Matrisin köşegenindeki yüksek değerler, doğru sınıflandırmaları temsil ederken, dışındaki değerler ise yanlış sınıflandırmaları belirtir. Bu matris, modelin sınıfları genellikle doğru bir şekilde ayırdığını gösterir. Ancak, bazı sınıflar arasında hala karışıklık olduğu görülmektedir, özellikle 1. sınıfın 3. sınıfa olan yanlış sınıflandırmaların sıklığı dikkat çekmiştir. Bununla birlikte, genel olarak, modelin test veri kümesinde yüksek bir doğruluk elde ettiği ve başarılı bir şekilde çeşitli sınıfları tanımlayabildiği söylenebilir.



Şekil 5. 15. MobileNetV2_İnceAyarlı Karmaşıklık Matrisi


MobileNetV2 modeli, üç farklı versiyonda incelenmiştir: temel, ağırlıklı ve ince ayarlı. Bu üç modelin de yüksek doğruluk oranları elde ettiği gözlemlenmiştir, bu da test veri kümesinde başarılı sınıflandırma yeteneklerine işaret etmektedir. MobileNetV2_Temel modeli, sınıflandırma performansı açısından dengeli sonuçlar vermiştir. MobileNetV2_Ağırlıklı modeli, doğru sınıflandırma ve düşük karışıklık matrisi değerleriyle öne çıkmaktadır. MobileNetV2_İnceAyarlı modeli ise yüksek doğruluk oranlarına ek olarak sınıflar arasında daha az karışıklık sergilemektedir. Bu sonuçlar, MobileNetV2'nin çeşitli ayarlarla güçlü bir sınıflandırma yeteneğine sahip olduğunu ve farklı sınıfları etkili bir şekilde ayırt edebildiğini göstermektedir. Bu performans, modelin çok yönlü ve esnek olduğunu ve çeşitli uygulama alanlarında kullanılabileceğini vurgulamaktadır.

5.5 DenseNet121 Mimarisi Sonuçları

Densenet121 mimarisi, üç farklı versiyonuyla incelenmiştir: Densenet121_Temel, Densenet121_Ağırlıklı ve Densenet121_İnceAyarlı. Bu üç yapılandırmanın performansını değerlendirmek için başarıım grafikleri, sınıf bazlı sonuçlar ve karmaşıklık matrisleri kullanılmıştır. Her bir modelin sınıflandırma yetenekleri detaylı bir şekilde incelenmiş ve farklı yapılandırmaların performans üzerindeki etkisi değerlendirilmiştir. Bu analizler, densenet121 modelinin farklı yapılandırmalarının sınıflandırma performansına olan etkisini değerlendirmiş, hangi ayarların daha iyi sonuçlar vereceğini belirlemiştir.

DenseNet121_temel, DenseNet121_ağırlıklı ve DenseNet121_inceayarlı modellerinin

performans grafikleri Şekil 5.16'da gösterilmiştir. Doğruluk ve kayıp grafiklerine bakıldığında, ağırlıklı ve ince ayarlı yöntemlerin, temel yönteme kıyasla modelin performansını daha hızlı ve istikrarlı bir şekilde artırdığı görülmektedir. İnce ayarlı yöntemin genellikle daha hızlı bir şekilde eğitildiği ve daha yüksek bir doğruluk elde ettiği gözlemlenmiştir. Bu bulgular, modelin daha iyi genelleme yeteneğine sahip olduğunu ve daha dengeli bir performans sunduğunu göstermektedir.



Şekil 5. 16. DenseNet121 Doğruluk ve Kayıp Grafikleri

Densenet121_Temel, Densenet121_Ağırlıklı ve Densenet121_İnceAyarlı modellerinin başarımlarının sunulmasının ardından, her bir modelin sınıf bazlı sonuçları incelenmiştir. Bu analiz, her modelin farklı sınıfları ne kadar doğru sınıflandırdığını ve hangi sınıflarda daha iyi veya daha zayıf performans gösterdiğini belirlemek için kullanılmıştır.

Tablo 5.13'te, DenseNet121_Temel modelinin performansı incelenmektedir. Genel doğruluk değeri orta seviyededir ve sınıflar arasında farklılıklar gözlemlenmektedir. Örneğin, "Endometri" sınıfında yüksek bir geri çağırma değeri, ancak düşük hassasiyet dikkat çekicidir, bu da modelin bu sınıfı tanımlamada duyarlı ancak belirlemede daha az kesin olabileceğini göstermektedir. "Mucinous" sınıfında ise düşük geri çağırma ve F1-puanı, modelin bu sınıfı doğru bir şekilde sınıflandırmakta zorlandığını işaret etmektedir. "Non_Cancerous" sınıfında da benzer bir durum gözlemlenmektedir, yani modelin bu sınıfı belirleme kabiliyeti, geri çağırma ve F1-puanı açısından iyileştirilmeye ihtiyaç duymaktadır. Sonuç olarak, modelin bazı sınıflarda iyi performans gösterdiği, ancak bazı sınıflarda ise geliştirilmeler yapılması gerektiği görülmektedir.

Tablo 5. 13. DenseNet121_Temel Sınıf Bazlı Sonuçlar

Sınıflar	Doğruluk	Hassasiyet	Geri Çağırma	F1-Puanı
Clear_Cell	0,74	0,88	0,70	0,78
Endometri	0,74	0,71	1,00	0,83
Mucinous	0,74	0,80	0,40	0,53
Non_Cancerous	0,74	0,64	0,90	0,75
Serous	0,74	0,78	0,70	0,74

DenseNet121_Temel sınıf bazlı sonuçları incelendikten sonra, geliştirilmesi gereken özellikler üzerine çalışılmış ve DenseNet121_Ağırlıklı mimarisi tasarlanmıştır. Bu yeni modelin sonuçları Tablo 5.14'te sunulmuştur.

Tablo 5. 14. DenseNet121_Ağırlıklı Sınıf Bazlı Sonuçlar

Sınıflar	Doğruluk	Hassasiyet	Geri Çağırma	F1-Puanı
Clear_Cell	0,88	0,86	0,86	0,86
Endometri	0,88	0,91	0,95	0,93
Mucinous	0,88	0,80	0,87	0,84
Non_Cancerous	0,88	0,92	0,87	0,89
Serous	0,88	0,95	0,87	0,91


Densenet121_Ağırlıklı modeli, her sınıf için yüksek hassasiyet, geri çağırma ve F1 puanı elde etmiştir, bu da modelin sınıfları doğru bir şekilde tanımlamada başarılı olduğunu göstermektedir. Özellikle, Endometri sınıfında elde edilen yüksek hassasiyet ve geri çağırma oranları, modelin bu belirli sınıfı başarıyla tanımlama kabiliyetini öne çıkarmaktadır.

Tablo 5.15'te, DenseNet121_İnceAyar modelinin sınıf bazlı sonuçlarını göstermektedir. Genel doğruluk değeri yüksektir ve sınıflar arasında tutarlı bir performans sergilenmektedir. Özellikle, "Endometri" sınıfında yüksek hassasiyet ve geri çağırma değerleri dikkat çekerken, "Clear_Cell" sınıfında da benzer şekilde yüksek bir hassasiyet görülmektedir. Ancak, "Mucinous" sınıfında hassasiyet diğer sınıflara göre biraz daha düşüktür ve "Serous" sınıfında geri çağırma değeri yüksektir ancak hassasiyet biraz daha düşüktür. Bu durum, modelin belirli sınıflarda daha iyi performans gösterdiğini ancak diğerlerinde hala iyileştirme potansiyeli olduğunu göstermektedir. Sonuç olarak, DenseNet121_İnceAyar modelinin, çeşitli sınıflardaki hücre türlerini tanımlamada oldukça etkili olduğu görülmektedir, ancak belirli sınıflarda hala odaklanması gereken noktalar bulunmaktadır.

Tablo 5. 15. DenseNet121_İnceAyar Sınıf Bazlı Sonuçlar

Sınıflar	Doğruluk	Hassasiyet	Geri Çağırma	F1-Puanı
Clear_Cell	0,87	0,90	0,82	0,86
Endometri	0,87	0,99	0,87	0,92
Mucinous	0,87	0,74	0,88	0,81
Non_Cancerous	0,87	0,88	0,86	0,87
Serous	0,87	0,88	0,92	0,90

Verilen sınıf bazlı sonuçlara göre, Densenet121_İnceAyarlı modeli genel olarak yüksek performans sergilemektedir. Densenet121_İnceAyarlı modelinin çeşitli sınıfları etkili bir şekilde sınıflandırdığı ve iyi bir performans sergilediği söylenebilir. Sınıf bazlı sonuçların incelenmesinin ardından, şimdi karmaşıklık matrisleri değerlendirilecek. DenseNet121_Temel için karmaşıklık matrisi Şekil 5.17'de sunulmuştur.

**Şekil 5. 17.** DenseNet121_Ağırlıklı Karmaşıklık Matrisi

Model en iyi performansı Endometri sınıfında göstermiş, burada hiç hata yapmamıştır. Non_Cancerous ve Serous sınıflarında da oldukça iyi sonuçlar elde edilmiştir. Ancak, model Mucinous sınıfında daha düşük performans sergilemiş ve daha fazla yanlış sınıflandırma yapmıştır. Bu değerlendirmeden sonra, DenseNet121_Ağırlıklı modelinin karmaşıklık matrisi Şekil 5.18'de verilmiştir.

Confusion Matrix (Test)

True Label \ Predicted Label	Clear_Cell	Endometri	Mucinous	Non_Cancerous	Serous
Clear_Cell	361	3	39	9	8
Endometri	0	391	13	3	4
Mucinous	28	9	367	10	6
Non_Cancerous	19	15	18	366	2
Serous	12	12	21	10	365

Şekil 5. 18. DenseNet121_İnceAyarlı Karmaşıklık Matrisi

DenseNet121_Ağırlıklı modelinin karmaşıklık matrisine bakıldığında modelin performansı tatmin edici olmakla birlikte, belirli sınıflar arasında iyileştirme potansiyeli bulunmaktadır. Son olarak DenseNet121_İnceAyarlı modelinin karmaşıklık matrisi Şekil 5.19’da incelenmiştir.

Confusion Matrix (Test)

True Label \ Predicted Label	Clear_Cell	Endometri	Mucinous	Non_Cancerous	Serous
Clear_Cell	344	0	46	10	20
Endometri	5	356	19	22	9
Mucinous	15	1	369	17	18
Non_Cancerous	5	0	46	361	8
Serous	13	2	16	1	388

Şekil 5. 19. DenseNet121_İnceAyarlı Karmaşıklık Matrisi

Tüm modellerin başarımlarını grafikleri, sınıf bazlı sonuçları ve karmaşıklık matrisleri paylaşıldıktan sonra, en iyi sonuçların ince ayar yapıldıktan sonra alındığı görülmüştür.

Tablo 5.16’da derin öğrenme ağlarının performanslarını karşılaştırılmıştır. Kullanılan ağlar arasında ResNet50, EfficientNetB0, InceptionV3, MobileNetV2 ve DenseNet121 yer

almaktadır. Her bir ağ, temel, ağırlıklı ve ince ayarlı olmak üzere üç farklı yöntemle test edilmiştir. Performans metrikleri olarak hassasiyet, geri çağırma, F1 skor ve doğruluk kullanılmıştır.

Tablo 5. 16. Kullanılan Modellerin Karşılaştırılması

Model	Kullanılan Yöntem	Hassasiyet	Geri Çağırma	F1 Skor	Doğruluk	Makro Ortalama
ResNet50	Temel	0,856	0,840	0,858	0,840	0,840
	Ağırlıklı	0,934	0,928	0,946	0,930	0,930
	İnce Ayarlı	0,952	0,952	0,950	0,950	0,950
EfficientB0	Temel	0,940	0,940	0,944	0,860	0,850
	Ağırlıklı	0,942	0,940	0,944	0,940	0,940
	İnce Ayarlı	0,968	0,968	0,968	0,970	0,970
InceptionV3	Temel	0,650	0,560	0,560	0,520	0,520
	Ağırlıklı	0,900	0,900	0,900	0,900	0,900
	İnce Ayarlı	0,690	0,680	0,690	0,680	0,690
MobileNetV2	Temel	0,690	0,600	0,590	0,600	0,590
	Ağırlıklı	0,720	0,690	0,690	0,690	0,690
	İnce Ayarlı	0,960	0,960	0,960	0,960	0,960
DenseNet121	Temel	0,760	0,740	0,730	0,740	0,730
	Ağırlıklı	0,890	0,890	0,890	0,880	0,890
	İnce Ayarlı	0,880	0,870	0,870	0,870	0,870


Tablo 5.16’da gösterilen ResNet50 ağının temel yöntemi ile yapılan değerlendirmede, hassasiyet ve doğruluk metriklerinde 0,856 ve 0,84 değerleri elde edilmiştir. Ancak, ağırlıklı yöntemde bu değerler 0,934 ve 0,93’a yükselmiş, ince ayarlı yöntemde ise 0,952 seviyesine ulaşarak en yüksek performansı göstermiştir. EfficientNet B0 ağının ince ayarlı yöntemi, tüm metriklerde 0,968-0,97 arasında değişen en yüksek değerleri sağlayarak, genel olarak en iyi performansı göstermiştir.

Inception V3 ağının temel yöntemi en düşük performansı sergilerken (hassasiyet ve doğruluk 0.65 ve 0.52), ağırlıklı yöntemle performans önemli ölçüde artmış ve ince ayarlı yöntemle de ortalama bir iyileşme göstermiştir. MobileNetV2'nin ince ayarlı yöntemi ise tüm metriklerde 0.96 gibi yüksek değerler elde etmiştir, bu da ağırlıklı ve temel yöntemlere göre belirgin bir iyileşme olduğunu göstermektedir.

MobileNetV2 ağının temel yöntemi ile yapılan testlerde hassasiyet 0.69, geri çağırma 0,60, F1 skoru 0,59 ve doğruluk 0,60 olarak elde edilmiştir. Bu değerler, MobileNetV2'nin temel haliyle orta seviyede bir performans sergilediğini göstermektedir. MobileNetV2'nin ağırlıklı yöntemi kullanıldığında, performans metriklerinde belirgin bir iyileşme gözlemlenmiştir. Hassasiyet 0,72,


geri çağırma 0,69, F1 skoru 0.69 ve doğruluk 0,69 olarak rapor edilmiştir. Bu sonuçlar, ağırlıklı yöntemin MobileNetV2'nin performansını artırdığını göstermektedir. MobileNetV2'nin ince ayarlı yöntemi ise tüm metriklerde 0,96 gibi yüksek değerler elde etmiştir, bu da ağırlıklı ve temel yöntemlere göre belirgin bir iyileşme olduğunu göstermektedir.

DenseNet121 ağında, temel yöntemle yapılan değerlendirmelerde orta seviyede performans gözlemlenmiş (hassasiyet 0,76), ağırlıklı yöntemle bu değer 0,89'a yükselmiş, ancak ince ayarlı yöntemde beklenmedik bir şekilde performans biraz düşerek 0,88 seviyelerinde kalmıştır.



Şekil 5. 20. EfficientB0 modelinin yanlış sınıflandırdığı örnek görüntüler

En iyi sonuçların alındığı EfficientNetB0 modeli üzerine yapılan ince ayar (fine-tuning) işlemi sonrasında modelin yanlış sınıflandırdığı ilk 20 görüntü Şekil 5.20’de gösterilmiştir. Yanlış sınıflandırma durumları, modelin hangi sınıflar arasında kararsız kaldığını ve hangi sınıflarda daha fazla hata yaptığını ortaya koymaktadır. Model, Clear Cell sınıfındaki örnekleri genellikle Mucinous ve Serous sınıfları ile karıştırmaktadır. Özellikle, Clear Cell ile Mucinous arasında belirgin bir karışıklık bulunmaktadır. Endometri sınıfındaki örneklerin de model tarafından Clear Cell ve Mucinous sınıflarıyla karıştırıldığı gözlemlenmiştir. Model, Mucinous sınıfındaki örnekleri doğru sınıflandırmakta zorlanmış ve bunları genellikle Clear Cell olarak tahmin etmiştir. EfficientNetB0 modelinin ince ayar işlemi sonucunda, belirli sınıflarda yüksek doğruluk oranlarına ulaşılsa da bazı sınıflar arasındaki karışıklık dikkat çekmektedir. Özellikle, benzer morfolojik özelliklere sahip sınıflar arasında modelin ayırım yapmada zorlandığı görülmektedir. Modelin doğru sınıflandırmadaki başarısının yanı sıra, yanılgıya düştüğü durumlar modelin iyileştirilmesi gereken alanlarını işaret etmektedir. Bu hatalar, eğitim veri setinde dengesizlikler veya belirli sınıfların diğerlerine göre daha zor ayırt edilebilir olmasıyla ilgili olabileceği belirlenmiştir.



Şekil 5. 21. Kullanılan modellerin karşılaştırılması

Şekil 5.21’de, kullanılan derin öğrenme modellerinin test verisi doğruluk oranlarının karşılaştırması yapılmaktadır. Her model üç farklı durumda değerlendirilmiştir: Temel, Ağırlıklı ve İnce Ayarlı. ResNet50 modeli, temel haliyle %84, ağırlıklı haliyle %93 ve ince ayarlı haliyle %95 doğruluk oranlarına ulaşmıştır. Bu sonuçlar, ResNet50'nin ince ayarlandığında en yüksek

performansa ulařtıđını gstermektedir. EfficientNetB0 modeli, temel durumda %86, ađırlıklı durumda %94 ve ince ayarlı durumda %97 dođruluk oranları ile tm modeller arasında en yksek dođruluk oranını elde etmiřtir. Inception V3 modeli, temel durumda %56, ađırlıklı durumda %90 ve ince ayarlı durumda %68 dođruluk oranlarına ulařmıřtır. Ađırlıklı Inception V3, diđer ayarlamalara kıyasla olduka yksek bir performans sergilemiřtir. MobileNetV2 modeli, temel durumda %60, ađırlıklı durumda %69 ve ince ayarlı durumda %96 dođruluk oranlarıyla, zellikle ince ayarlandığında ok yksek bir performans gstermiřtir. DenseNet121 modeli, temel durumda %74, ađırlıklı durumda %88 ve ince ayarlı durumda %87 dođruluk oranlarına sahiptir. Ađırlıklı ve ince ayarlı DenseNet121 modelleri benzer performans sergilemiřtir. Genel olarak, ince ayar yapılmıř modeller, temel ve ađırlıklı modellerden daha yksek dođruluk oranlarına sahiptir. EfficientNetB0 ve MobileNetV2 modelleri, ince ayarlandıklarında en yksek dođruluk oranlarına ulařmıřtır. Bu grafik, model seiminde ince ayarın nemli bir etkisi olduđunu ortaya koymaktadır.

6. SONUÇ VE ÖNERİLER

Bu çalışma, yumurtalık kanseri sınıflandırması için çeşitli derin öğrenme modellerinin performansını değerlendirmeyi amaçlamıştır. Resnet50, EfficientB0, InceptonV3, MobileNetV2, DenseNet121 modelleri üç farklı ortamda doğruluk, hassasiyet, geri çağırma, F1-skor metrikleri ile değerlendirilmiştir. Değerlendirilen üç farklı ortamdan birincisi temel olarak adlandırdığımız orijinal veri seti üzerinde gerçekleştirilirken, ağırlıklı olarak adlandırdığımız ortamda veri artırma yöntemleri kullanılırken, sınıf ağırlıkları da kullanılmıştır. Kıyaslanan son ortamda ise ağırlıklı ortama ek olarak ince ayar yöntemi kullanılmış ve ince ayarlı olarak adlandırılmıştır.

Bu ortamlardan elde edilen sonuçlar, belirli modellerin belirli sınıflar için daha iyi performans gösterebileceğini ve iyileştirme alanlarının olduğunu ortaya koymaktadır. Sonuçlar ince ayarlı modellerin genellikle daha yüksek performans gösterdiğini göstermektedir. Özellikle, EfficientB0 modeli tüm sınıflarda yüksek hassasiyet ve geri çağırma oranlarına ulaşarak en yüksek doğruluk oranlarına sahip olmuştur. Bununla birlikte, Mucinous sınıfında InceptionV3 modelinin düşük performans sergilediği gözlemlenmiştir. Bu durum, belirli sınıflar için belirli modellerin daha uygun olduğunu göstermektedir.

Ayrıca, bu çalışma, model performansını artırmak için çeşitli tekniklerin etkisi değerlendirilmiştir. Veri artırma yöntemleri, modelin genel genelleme yeteneğini artırmak için kullanılmıştır. Ek olarak, sınıf ağırlıkları, çapraz entropi kaybı ve dropout gibi model parametreleri ayarlanmıştır. Bu parametrelerin dikkati bir şekilde ayarlanmasıyla, modelin daha iyi sınıflandırma performansı elde ettiği gözlenmiştir. Bu çalışma, modelin daha genel bir veri kümesine daha iyi uyarlanabilmesi için bu tür tekniklerin önemini vurgulamaktadır.

Çalışmada kullanılan modeller, 25 epok boyunca eğitilmiş ve toplamda yaklaşık 19 bin görüntü kullanılmıştır. Ancak, bu modellerin yüksek RAM gereksinimleri, Google Colab gibi sınırlı RAM kaynaklarına sahip ortamlarda çalışırken zorluklar yaşanmasına neden olmuştur. Bu durum, model eğitim sürelerinin uzun olmasını ve bellek kullanımının artmasını tetiklemiştir. Daha büyük veri setleriyle çalışmanın, model performansını artırmak için alternatif bir yaklaşım olabilir.

Gelecekteki çalışmalarda, daha geniş ve dengeli bir veri kümesi kullanılması hedeflenmektedir. Daha fazla veri, modelin genelleme performansını iyileştirebilir. Farklı hiper parametre ayarlarının ve model mimarilerinin test edilmesi, daha iyi performans elde etmek için potansiyel bir stratejidir. Özellikle, belirli sınıflar için uygun olan modelin belirlenmesine

yardımcı olabilir. Transfer öğrenme tekniklerinin daha fazla araştırılması faydalı olabilir. Önceden eğitilmiş modellerin kullanılması, daha az veriyle daha iyi performans elde etmek için etkili bir yol olabilir. Modelin yanlış sınıflandırdığı örneklerin incelenmesi, modelin zayıf noktalarının belirlenmesine ve iyileştirme alanlarının tanımlanmasına yardımcı olabilir. Bu öneriler, gelecekteki çalışmaların yumurtalık kanseri sınıflandırması alanında daha iyi performans elde etmesine ve klinik uygulamalara daha fazla katkı sağlamasına yardımcı olabilir.



KAYNAKÇA

- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Farhan, L.** (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 8(1).
- Atila, Ü., Uçar, M., Akyol, K., Informatics, E. U.-E. & 2021, U.** (2021). Plant leaf disease classification using EfficientNet deep learning model. *Elsevier*.
- Bishop, Christopher M., & N. M.** (2006). Pattern recognition and machine learning. *Bishop, C. M., & Nasrabadi, N. M. (2006). Pattern recognition and machine learning (Vol. 4, No. 4, p. 738). New York: springer. <https://link.springer.com/in/book/9780387310732> from retrieved.*
- Bodapati, J. D., Feroz, S., Yarra, A., Chowdary, Y. & Sekhar, K. R.** (2023). Enhancing brain tumor diagnosis using a multi-architecture deep convolutional neural network on MRI scans. *library.acadlore.comJD BodapatiInf. Dyn. Appl, 2023•library.acadlore.com*, 2(1), 42–50.
- Bowtell, David D., Böhm, S., Ahmed, A. A., Aspuria, P. J., Bast, R. C., Beral, V., Balkwill, F. R.** (2015). Rethinking ovarian cancer II: Reducing mortality from high-grade serous ovarian cancer. *Nature Reviews Cancer*, 15(11), 668–679.
- Bowtell, David DL.** (2010). The genesis and evolution of high-grade serous ovarian cancer. *nature.comDDL BowtellNature Reviews Cancer, 2010,nature.com*.
- Bray, F., Ferlay, J., Soerjomataram, I., Siegel, R. L., Torre, L. A. & Jemal, A.** (2018). Global cancer statistics 2018: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries. *Wiley Online LibraryF Bray, J Ferlay, I Soerjomataram, RL Siegel, LA Torre, A JemalCA: a cancer journal for clinicians, 2018•Wiley Online Library*, 68(6), 394–424.
- Breen, J., Allen, K., Zucker, K., P. A.-N. P, U.** (2023). Artificial intelligence in ovarian cancer histopathology: a systematic review. *nature.comJ Breen, K Allen, K Zucker, P Adusumilli, A Scarsbrook, G Hall, NM Orsi, N RavikumarNPJ Precision Oncology, 2023•nature.com*.
- Celik, Y., Talo, M., Yildirim, O., Karabatak, M. & Acharya, U. R.** (2020). Automated invasive ductal carcinoma detection based using deep transfer learning with whole-slide images. *Pattern Recognition Letters*, 133, 232–239.
- Chollet, F.** (2021). Deep learning with Python.
- Deniz, C., Bahçeşehir, G., İstanbul, Ü. & İstanbul, B. Ü.** (2018). Evrişimli Sinir Ağlarında Eğitim Transferi için Örnek Çalışma A Case Study on Transfer Learning in Convolutional Neural Networks Nafiz ARICA.

Dong, K., Zhou, C., Ruan, Y., International, Y. L, U. (2020). MobileNetV2 model for image classification. *ieeexplore.ieee.org* K Dong, C Zhou, Y Ruan, Y Li 2020 2nd International Conference on Information Technology and, 2020•*ieeexplore.ieee.org*.

Egrioglu, E., Aladag, C., Yolcu, U., V. U.-E. S. with & 2009, U. (2009). A new approach based on artificial neural networks for high order multivariate fuzzy time series. *Elsevier*.

Farahani, H., Boschman, J., Farnell, D., Darbandsari, A., Zhang, A., Ahmadvand, P., Bashashati, A. (2022). Deep learning-based histotype diagnosis of ovarian carcinoma whole-slide pathology images. *Modern Pathology*, 35(12), 1983–1990.

Gershenson, D. M (2016). Low-grade serous carcinoma of the ovary or peritoneum. *Elsevier* DM Gershenson *Annals of Oncology*, 2016•*Elsevier*.

Ghoniem, R., Refky, B., Abd, A., Ewees, E., Ghoniem, R. M., Algarni, A. D. & Ewees, A. A. (2021). Multi-Modal Evolutionary Deep Learning Model for Ovarian Cancer Diagnosis. *Symmetry* 2021, 13, 643.

Goodfellow, I., Bengio, Y. & Courville, A. (2016). Example Notation for Deep Learning.

Ho, D. J., Chui, M. H., Vanderbilt, C. M., Jung, J., Robson, M. E., Park, C. S., Fuchs, T. J. (2023). Deep Interactive Learning-based ovarian cancer segmentation of H&E-stained whole slide images to study morphological patterns of BRCA mutation. *Journal of Pathology Informatics*, 14.

Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Adam, H. (2017). MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications. <http://arxiv.org/abs/1704.04861> from retrieved.

Huang, G., Liu, Z., L. V. D. M.-P. of the & 2017, U. (2017). Densely connected convolutional networks. *openaccess.thecvf.com* G Huang, Z Liu, L Van Der Maaten, KQ Weinberger *Proceedings of the IEEE conference on computer vision and, 2017*•*openaccess.thecvf.com*.

Ioffe, S. & Machine, C. S.-I. conference on. (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift. *proceedings.mlr.press* S Ioffe, C Szegedy *International conference on machine learning, 2015*•*proceedings.mlr.press*. <http://proceedings.mlr.press/v37/ioffe15.html> from retrieved.

Jayson, G. C., Kohn, E. C., Kitchener, H. C. & Ledermann, J. A. (2014). Ovarian cancer. *The Lancet*, 384(9951), 1376–1388.

Kasture, K. (2021). OvarianCancer&SubtypesDatasetHistopathology, 1.

Kasture, K. R., Sayankar, B. B. & Matte, P. N. (2021). Multi-class Classification of Ovarian

Cancer from Histopathological Images using Deep Learning - VGG-16. *2021 2nd Global Conference for Advancement in Technology, GCAT 2021*.

Kasture, K. R., Shah, D. D. & Matte, P. N. (2021). A New Deep Learning method for Automatic Ovarian Cancer Prediction & Subtype classificationin 1. *Turkish Journal of Computer and Mathematics Education*, 12(12), 1233–1242.

Kavitha, S., Dhanapriya, B., Vignesh, G. N. & Baskaran, K. R. (2021). Neural Style Transfer Using VGG19 and Alexnet. *2021 International Conference on Advancements in Electrical, Electronics, Communication, Computing and Automation, ICAECA 2021*.

Kilicarslan, S., Adem, K., Hypotheses, M. C.-M. & 2020, U. (2020). Diagnosis and classification of cancer using hybrid model based on ReliefF and convolutional neural network. *Elsevier*.

Kizrak, M. A., & Bolat, B. (2018). Derin öğrenme ile kalabalık analizi üzerine detaylı bir araştırma. *dergipark.org.trMA Kızrak, B BolatBilişim Teknolojileri Dergisi, 2018•dergipark.org.tr*.

Köbel, M., Kalloger, S. E., Boyd, N., McKinney, S., Mehl, E., Palmer, C., Huntsman, D. (2008). Ovarian carcinoma subtypes are different diseases: Implications for biomarker studies. *PLoS Medicine*, 5(12), 1749–1760.

Kodipalli, A., Guha, S., Dasar, S., Systems, T. I.-E. (2022). An inception-ResNet deep learning approach to classify tumours in the ovary as benign and malignant. *Wiley Online Library*.

Krizhevsky, A., Sutskever, I., ACM, G. H.-C . (2017). ImageNet classification with deep convolutional neural networks. *dl.acm.org*, 60(6), 84–90.

Kurman, R. & Pathology, I. S.-T. A (2010). The origin and pathogenesis of epithelial ovarian cancer: a proposed unifying theory. *journals.lww.com*.

LeCun, Y., Bengio, Y., Nature, G. H. (2015). Deep learning. *nature.comY LeCun, Y Bengio, G Hintonnature, 2015•nature.com*. vgJcC16uRwnm4TAfrzDXvg from retrieved.

Levine, A. B., Peng, J., Farnell, D., Nursey, M., Wang, Y., Naso, J. R., Bashashati, A. (2020). Synthesis of diagnostic quality cancer pathology images by generative adversarial networks. *Journal of Pathology*, 252(2), 178–188.

Lheureux, S., Braunstein, M. & Oza, A. M. (2019). Epithelial ovarian cancer: Evolution of management in the era of precision medicine. *CA: A Cancer Journal for Clinicians*, 69(4), 280–304.

Liang, X., Wu, L., Li, J., Wang, Y., Meng, Q., Qin, T., Liu, T.-Y. (2021). R-drop:

Regularized dropout for neural networks. *proceedings.neurips.cc* L Wu, J Li, Y Wang, Q Meng, T Qin, W Chen, M Zhang, TY Liu *Advances in Neural Information Processing Systems, 2021*•*proceedings.neurips.cc*.

Maeda, D., Pathology, I. S.-A U. (2013). Pathogenesis and the role of ARID1A mutation in endometriosis-related ovarian neoplasms. *journals.lww.com*.

McCluggage, W. G. (2008). My approach to and thoughts on the typing of ovarian carcinomas. *jcp.bmj.com* WG McCluggage *Journal of clinical pathology, 2008*•*jcp.bmj.com*.

Mukti, I. & On, D. B. (2019). Transfer learning based plant diseases detection using ResNet50. *ieeexplore.ieee.org* IZ Mukti, D Biswas *2019 4th International conference on electrical information and, 2019*•*ieeexplore.ieee.org*.

Murphy, K. (2012). Machine learning: a probabilistic perspective.

Nero, C., Boldrini, L., Lenkiewicz, J., M. G.-I. J. U. (2022). Deep-learning to predict BRCA mutation and survival from digital H&E slides of epithelial ovarian cancer. *mdpi.com* C Nero, L Boldrini, J Lenkiewicz, MT Giudice, A Piermattei, F Inzani, T Pasciuto, A Minucci *International Journal of Molecular Sciences, 2022*•*mdpi.com*.

Norquist, B., Harrell, M., Brady, M., T. W.-J. (2016). Inherited mutations in women with ovarian carcinoma. *jamanetwork.com*.

Oswald, A. J. & Gourley, C. (2015). Low-grade epithelial ovarian cancer: A number of distinct clinical entities? *Current Opinion in Oncology, 27*(5), 412–419.

Paoletti, M., Haut, J., Plaza, J., Photogrammetry, A. P.-I. J (2019). Deep learning classifiers for hyperspectral imaging: A review. *Elsevier* ME Paoletti, JM Haut, J Plaza, A Plaza *ISPRS Journal of Photogrammetry and Remote Sensing, 2019*•*Elsevier*. h

Platania, R., Shams, S., Yang, S., Zhang, J., K. L.-P. (2017). Automated breast cancer diagnosis using deep learning and region of interest detection (bc-droid). *dl.acm.org* R Platania, S Shams, S Yang, J Zhang, K Lee, SJ Park *Proceedings of the 8th ACM international conference on bioinformatics, 2017*•*dl.acm.org, 17*, 536–543.

Sandler, M., Howard, A., Zhu, M., Zhmoginov, A. & Chen, L.-C. (2018). Mobilenetv2: Inverted residuals and linear bottlenecks. *openaccess.thecvf.com* M Sandler, A Howard, M Zhu, A Zhmoginov, LC Chen *Proceedings of the IEEE conference on computer vision and, 2018*•*openaccess.thecvf.com*.

Sathwik, A. S., Naseeba, B., Kiran, J. C., Lokesh, K., Sasi, V., Ch, D. & Challa, N. P. (2023). Early Detection of Monkeypox Skin Disease Using Patch Based DL Model and Transfer Learning Techniques. *publications.eai.eu* AS Sathwik, B Naseeba, JC Kiran, K Lokesh, VSD Ch,

NP ChallaEAI Endorsed Transactions on Pervasive Health and Technology, 2023•publications.eai.eu, 1.

Saxena, S., Shrivastava, J., G. A.-H. (2023). Classification of kidney diseases using transfer learning. *igi-global.com*. <https://www.igi-global.com/chapter/classification-of-kidney-diseases-using-transfer-learning/318846> from retrieved.

Seidman, J., R. K.-T. A. (2003). Primary and metastatic mucinous adenocarcinomas in the ovaries: incidence in routine practice with a new approach to improve intraoperative diagnosis.

Shabbir, A., Ali, N., Ahmed, J., B. Z.-M. (2021). Satellite and scene image classification based on transfer learning and fine tuning of ResNet50. *hindawi.com* A Shabbir, N Ali, J Ahmed, B Zafar, A Rasheed, M Sajid, A Ahmed, SH DarMathematical Problems in Engineering, 2021•hindawi.com.

Slomovitz, B., Gourley, C., Carey, M. S., Malpica, A., Shih, I.-M., Huntsman, D., Gershenson, D. M. (2020). Low-grade serous ovarian cancer: State of the science.

Srivastava, N., Hinton, G., A. K.-T. (2014). Dropout: a simple way to prevent neural networks from overfitting. *jmlr.org*, 15, 1929–1958.

Sugiyama, T., Kamura, T., J. K. (2000). Clinical characteristics of clear cell carcinoma of the ovary: a distinct histologic type with poor prognosis and resistance to platinum-based chemotherapy. *Wiley Online Library* T Sugiyama, T Kamura, J Kigawa, N Terakawa, Y Kikuchi, T Kita, M Suzuki, I Sato, K TaguchiCancer: Interdisciplinary International Journal of the American, 2000

Sung, H., Ferlay, J., Siegel, R. L., Laversanne, M., Soerjomataram, I., Jemal, A. & Bray, F. (2021). Global Cancer Statistics 2020: GLOBOCAN Estimates of Incidence and Mortality Worldwide for 36 Cancers in 185 Countries. *CA: A Cancer Journal for Clinicians*, 71(3), 209–249.

Szegedy, C., Vanhoucke, V., S. I.-P. (2016). Rethinking the inception architecture for computer vision. *cv-foundation.org* C Szegedy, V Vanhoucke, S Ioffe, J Shlens, Z WojnaProceedings of the IEEE conference on computer vision and pattern, 2016•cv-foundation.org.

Talahua, J., Buele, J., Calvopiña, P., Sustainability, J. V.-A. (2021). Facial recognition system for people with and without face mask in times of the covid-19 pandemic. *mdpi.com* JS Talahua, J Buele, P Calvopiña, J Varela-AldásSustainability, 2021•mdpi.com.

Tan, M. & Le, Q. V. (2019). EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. *openreview.net*.

- Tang, Y., Liu, M., Hu, L., Wang, C., He, Y., Zeng, C., Huo, W.** (2022). A deep learning method for breast cancer classification in the pathology images. *ieeexplore.ieee.org* M Liu, L Hu, Y Tang, C Wang, Y He, C Zeng, K Lin, Z He, W Huo *IEEE Journal of Biomedical and Health Informatics*, 2022•*ieeexplore.ieee.org*, 26(10), 5025.
- Tasya, W., Sa'idah, S., B. H** (2022). Breast Cancer Detection Using Convolutional Neural Network with EfficientNet Architecture. *ieeexplore.ieee.org* W Tasya, S Sa'idah, B Hidayat, F Nurfajar 2022 *IEEE Asia Pacific Conference on Wireless and Mobile (APWiMob)*, 2022•*ieeexplore.ieee.org*..
- Tezcan, C., Kiras, B., Processing, G. B.** (2022). Classification of Breast Cancer Histopathological Images with Deep Transfer Learning Methods. *ieeexplore.ieee.org* CE Tezcan, B Kiras, G Bilgin 2022 *30th Signal Processing and Communications Applications*, 2022•*ieeexplore.ieee.org*.
- Tian, X., Daigle, H., Unconventional, H. J.-S** (2018). Feature detection for digital images using machine learning algorithms and image processing. *onpetro.org* X Tian, H Daigle, H Jiang SPE/AAPG/SEG *Unconventional Resources Technology Conference*, 2018•*onpetro.org*.
- Vrbančič, G. & Access, V. P.-I.** (2020). Transfer learning with adaptive fine-tuning. *ieeexplore.ieee.org* G Vrbančič, V Podgorelec *IEEE Access*, 2020•*ieeexplore.ieee.org*.
- Wang, H., Liu, C., Zhao, Z., Zhang, C., Wang, X., Li, H., Ma, W.** (2021). Application of Deep Convolutional Neural Networks for Discriminating Benign, Borderline, and Malignant Serous Ovarian Tumors From Ultrasound Images. *Frontiers in Oncology*, 11.
- Young, R.** (2014). WHO classification of tumours of female reproductive organs. *kubalibri.cz*.
- Yu, K. H., Hu, V., Wang, F., Matulonis, U. A., Mutter, G. L., Golden, J. A. & Kohane, I. S.** (2020). Deciphering serous ovarian carcinoma histopathology and platinum response by convolutional neural networks. *BMC Medicine*, 18(1).
- Zhang, G., Patuwo, B., Forecasting, M. H.-I.** (1998). Forecasting with artificial neural networks:: The state of the art. *Elsevier*.
- Zhang, J., Li, Y., Zou, J., Lai, C. T., Zeng, T., Peng, J., Li, Y. K.** (2022). Comprehensive analysis of the glutathione S-transferase Mu (GSTM) gene family in ovarian cancer identifies prognostic and expression significance. *Frontiers in Oncology*, 12.
- Zhou, L., Zhang, C., Liu, F., Z. Q.** (2019). Application of deep learning in food: a review. *Wiley Online Library*, 18(6), 1793–1811.
- Ziyambe, B., Yahya, A., Mushiri, T., Tariq, M., Diagnostics,** (2023). A deep learning framework for the prediction and diagnosis of ovarian cancer in pre-and post-menopausal

women. *mdpi.com* B Ziyambe, A Yahya, T Mushiri, MU Tariq, Q Abbas, M Babar, M Albathan, M Asim *Diagnostics*, 2023 • *mdpi.com*.

